



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

**SEGMENTACE KLENBY LEBEČNÍ U PACIENTŮ PO
KRANIEKTOMII**

SEGMENTATION OF CRANIAL BONE AFTER CRANIECTOMY

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Pavlína Vavřinová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Roman Jakubíček

BRNO 2020

Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Bc. Pavlína Vavřínová

ID: 186700

Ročník: 2

Akademický rok: 2019/20

NÁZEV TÉMATU:

Segmentace klenby lebeční u pacientů po kraniektomii

POKYNY PRO VYPRACOVÁNÍ:

1) Seznamte se s anatomíí kostí lebky a zobrazování pomocí CT modality. Nastudujte informace o kraniektomii, její indikaci, následky a možnosti náhrad kostí klenby lebeční (kranioplastiky). 2) Prostudujte dostupné metody segmentace se zaměřením na metody strojového učení, zejména konvolučních neuronových sítí. Vypracujte literární rešerši publikovaných řešení dané problematiky. 3) Navrhněte metodiku s využitím konvolučních neuronových sítí pro segmentaci klenby lebeční v CT datech. Využijte anotovanou databázi CT skenů pacientů po kraniektomii. 4) Navrženou metodu implementujte ve zvoleném programovém prostředí. Proved'te prvotní statistické vyhodnocení úspěšnosti segmentace. 5) Optimalizujte architekturu sítě a její hyperparametry se zaměřením na přesnost segmentace v oblastech po chirurgickém zákroku. 6) Diskutujte dosažené výsledky a možnosti využití segmentace v kranioplastice.

DOPORUČENÁ LITERATURA:

[1] RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-net: Convolutional networks for biomedical image segmentation. In: International Conference on Medical image computing and computer-assisted intervention. Springer, Cham, 2015. p. 234-241.

[2] MINNEMA, Jordi, et al. CT image segmentation of bone for medical additive manufacturing using a convolutional neural network. Computers in biology and medicine, 2018, 103: 130-139.

Termín zadání: 3.2.2020

Termín odevzdání: 29.5.2020

Vedoucí práce: Ing. Roman Jakubíček

prof. Ing. Stanislav Hanus, CSc.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Tato práce se zabývá segmentací klenby lebeční v CT snímcích pacientů po kraniektomii. Zadaná problematika byla řešena pomocí segmentační architektury U-Net, konkrétně její 2D i 3D variantou. S první verzí architektury bylo dosaženo průměrné hodnoty Jaccardova indexu 89,4 %, u druhé úspěšnosti 67,1 % vyhodnocené stejnou metrikou. Při zaměření na oblasti po chirurgickém zákroku nebyl u výsledků jednotlivých variant již tak velký rozdíl, zjištěný Jaccardův index pro 2D síť byl průměrně 98,4 % a pro 3D verze 97,0 %.

KLÍČOVÁ SLOVA

dekompresivní zákroky, hluboké učení, konvoluční neuronové sítě, U-Net

ABSTRACT

This thesis deals with the segmentation of cranial bone in CT patient's data after craniectomy. The U-Net architecture in 2D and 3D variant were selected for the intention of solving this problem. Jaccard index for 2D U-Net was evaluate as 89,4 % and for 3D U-Net it was 67,1 %. In the area after surgical intervention evaluating index has smaller difference between both variant, the average success rate of skull classification was 98,4 % for 2D U-Net and 97,0 % for 3D U-Net.

KEYWORDS

decompression operation, deep learning, convolutional neural networks, U-Net

VAVŘINOVÁ, Pavlína. *Segmentace klenby lebeční u pacientů po kraniektomii*. Brno, 2020, 79 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Roman Jakubíček

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Segmentace klenby lebeční u pacientů po kraniektomii“ jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno

.....

podpis autorky

PODĚKOVÁNÍ

Děkuji svému vedoucímu Ing. Romanu Jakubíčkoví za odborné vedení, trpělivost a věnovaný čas. Také bych ráda poděkovala firmě TESCANA Medical s.r.o. za zapůjčená data, jmenovitě doc. Ing. Přemyslu Krškovi, Ph.D. a Ing. Michaeli Novosadové.

Obsah

Úvod	11
1 Dekompresivní zákroky na lebce	12
1.1 Anatomie lebky	12
1.1.1 Obličejová část lebky	12
1.1.2 Mozková část lebky	12
1.2 Zobrazování hlavy pomocí CT modality	13
1.2.1 Princip CT	14
1.3 Dekompresivní operace	14
1.3.1 Dekompresivní kraniotomie	15
1.3.2 Dekompresivní kraniektomie	15
1.3.3 Kranioplastika	17
2 Segmentace	21
2.1 Klasické segmentační přístupy	21
2.2 Využití strojového učení pro segmentaci	22
2.2.1 Hluboké učení	23
2.3 Konvoluční neuronové sítě	23
2.3.1 Architektura	24
2.3.2 Trénovací algoritmy	26
2.3.3 Segmentační architektury	27
3 Předchozí práce	29
4 Datová sada	32
4.1 Akvizice dat	32
4.2 Anotace dat	32
4.3 Předzpracování dat	32
5 Návrh a implementace	34
5.1 Architektura 2D sítě	34
5.2 Architektura 3D sítě	35
5.3 Metriky hodnocení úspěšnosti	36
5.4 Finální úpravy predikovaných snímků	37
6 Experimenty a výsledky	38
6.1 2D U-Net	38
6.1.1 Datová množina pro 2D síť	38

6.1.2	Výběr ztrátové funkce	38
6.1.3	Trénování 2D sítí	40
6.1.4	Finální úpravy	43
6.2	3D U-Net	46
6.2.1	Datová množina pro 3D síť	46
6.2.2	Volba přístupu trénování a testování	46
6.2.3	Trénování 3D sítí	49
6.3	Srovnání výsledků 2D a 3D sítě	51
6.3.1	3D vizualizace výsledků	52
6.3.2	Analýza segmentace v oblastech po chirurgickém zákroku . . .	54
6.3.3	Využití výsledků při plánování kranioplastiky	54
Závěr		56
Literatura		58
Seznam příloh		63
A Výsledky testování 2D sítě		64
B Ukázky výstupů testování 2D sítí		65
C Výsledky 2D sítí po finálních úpravách		69
D Výsledky 3D sítí		70
E Ukázky výstupů testování 3D sítí		71
F Srovnání 2D a 3D sítí		73
G Grafické srovnání 2D a 3D sítí		75

Seznam obrázků

1.1	Kontrolní CT snímky po provedené kraniektomii	17
1.2	Kranioplastika s umělým implantátem.	18
1.3	Syndrom propadlé kůže.	19
1.4	Implantát z titanové mřížky.	20
1.5	Implantát z PEEK vlákna a hydroxyapatitu.	20
2.1	Graf funkce ReLU	24
2.2	Princip max pooling vrstvy.	26
2.3	Architektura U-Net	28
4.1	Ukázka anotovaných dat.	33
5.1	Schéma 2D architektury.	35
5.2	Schéma 3D architektury.	36
6.1	Příklad klasifikace - ztrátová funkce cross entropy.	39
6.2	Příklad klasifikace - Diceova ztrátová funkce.	39
6.3	Příklad klasifikace - fokální ztrátová funkce.	40
6.4	Ukázka výstupu 2D sítě - klenba lebeční	42
6.5	Ukázka výstupu 2D sítě - dutiny	42
6.6	Ukázka výstupu sítě - dutiny a spodina lebeční	43
6.7	Finální úprava - artefakt aktivních kontur	44
6.8	Finální úprava - mediánový filtry a aktivní kontury	44
6.9	Finální úpravy -ukázka	45
6.10	Výběr velikosti 3D kostky.	47
6.11	Predikce 3D sítě po 10 epochách.	48
6.12	Průběh učení 3D sítě.	48
6.13	Ukázka výstupu 3D sítě - klenba lebeční	50
6.14	Ukázka výstupu 3D sítě - dutiny	50
6.15	Ukázka výstupu 3D sítě - špatně určené dutiny	50
6.16	Grafické srovnání výstupu 2D a 3D sítě - ukázka 1	52
6.17	Grafické srovnání výstupu 2D a 3D sítě - ukázka 2	53
6.18	3D vizualizace výsledků	53
6.19	Analýza oblasti po chirurgickém zákroku.	54
B.1	Grafický výstup 2D sítě - ukázka 1	65
B.2	Grafický výstup 2D sítě - ukázka 2	65
B.3	Grafický výstup 2D sítě - ukázka 3	66
B.4	Grafický výstup 2D sítě - ukázka 4	66
B.5	Grafický výstup 2D sítě - ukázka 5	66
B.6	Grafický výstup 2D sítě - ukázka 6	67
B.7	Grafický výstup 2D sítě - ukázka 7	67

B.8	Grafický výstup 2D sítě - ukázka 8	67
B.9	Grafický výstup 2D sítě - ukázka 9	68
B.10	Grafický výstup 2D sítě - ukázka 10	68
B.11	Grafický výstup 2D sítě - ukázka 11	68
E.1	Grafický výstup 3D sítě - ukázka 1	71
E.2	Grafický výstup 3D sítě - ukázka 2	71
E.3	Grafický výstup 3D sítě - ukázka 3	72
E.4	Grafický výstup 3D sítě - ukázka 4	72
E.5	Grafický výstup 3D sítě - ukázka 5	72
G.1	Grafické srovnání výstupu 2D a 3D sítě - ukázka 3	75
G.2	Grafické srovnání výstupu 2D a 3D sítě - ukázka 4	75
G.3	Grafické srovnání výstupu 2D a 3D sítě - ukázka 5	76
G.4	Grafické srovnání výstupu 2D a 3D sítě - ukázka 6	76
G.5	Grafické srovnání výstupu 2D a 3D sítě - ukázka 7	76
G.6	Grafické srovnání výstupu 2D a 3D sítě - ukázka 8	77
G.7	Grafické srovnání výstupu 2D a 3D sítě - ukázka 9	77
G.8	Grafické srovnání výstupu 2D a 3D sítě - ukázka 10	77
G.9	Grafické srovnání výstupu 2D a 3D sítě - ukázka 11	78
G.10	Grafické srovnání výstupu 2D a 3D sítě - ukázka 12	78
G.11	Grafické srovnání výstupu 2D a 3D sítě - ukázka 13	78
G.12	Grafické srovnání výstupu 2D a 3D sítě - ukázka 14	79
G.13	Grafické srovnání výstupu 2D a 3D sítě - ukázka 15	79
G.14	Grafické srovnání výstupu 2D a 3D sítě - ukázka 16	79

Seznam tabulek

6.1	Tabulka velikostí datových množin pro 2D U-Net.	38
6.2	Část tabulky výsledků testovaných 2D sítí.	41
6.3	Část tabulky výsledků testovaných 3D sítí.	49
6.4	Tabulka srovnání výsledků 2D a 3D sítí.	51
6.5	Tabulka výsledků analýzy oblastí po chirurgickém zákroku.	55
A.1	Tabulka výsledků testovaných 2D sítí.	64
C.1	Tabulka výsledků testovaných 2D sítí po finálních úpravách.	69
D.1	Tabulka výsledků testovaných 3D sítí.	70
F.1	Tabulka srovnání výsledků 2D a 3D sítí - metrika ACC.	73
F.2	Tabulka srovnání výsledků 2D a 3D sítí - metrika IoU.	74

Úvod

Kraniektomie je dekompresivní operace, která pacienta může zachránit v život ohrožujícím stavu. Pokud v pooperačním období nenastanou vážné komplikace a pacientův stav je stabilizován, je možné provést kranioplastiku, díky které se obnoví mechanická funkce lebečních kostí. Pro obě ze zmíněných operací je pro proces plánování užitečný systém automaticky segmentující klenbu lebeční. Pokud má například lékař k dispozici systém segmentující oblast zájmu, provede pouze kontrolu a doladění detailů a může se tak výrazně zkrátit doba přípravy operace nebo výrobních procesů implantátu.

První kapitola této práce se zabývá dekompresivními zákroky, jejich indikací, postupem a komplikacemi, dále je zde stručně shrnuta anatomie lebky a princip zobrazování pomocí CT systémů. Druhá kapitola je zaměřená na teorii segmentačních přístupů - klasických i těch, co využívají strojového učení, především pak se zaměřením na konvoluční neuronové sítě - jejich architekturu a nejznámější segmentační architektury. Ve třetí kapitole je vypracována literární rešerše odborných článků zabývajících se segmentací, nejčastěji za využití architektury U-Net nebo některé její modifikace. Čtvrtá kapitola a pátá kapitola obsahuje nastínění procesu vytvoření datové sady, výběru architektur a jejich úprav, podrobný popis vybrané sítě a vysvětlení, jak byla vypočítána úspěšnost. V šesté kapitole jsou shrnuty provedené experimenty a jejich výsledky.

1 Dekompresivní zákroky na lebce

Informace o rozmístění, vlastnostech, tvaru a návaznosti kostí je důležitá už při plánování dekompresivního zákroku, kdy je třeba brát zřetel i na rizika vývoje po operaci. Stručný popis lebečních kostí se nachází v části 1.1. V této problematice je zásadní zobrazení hlavy pomocí CT systému (popsané v části 1.2), díky němuž se může indikovat dekompresivní zákrok i sledovat pooperační stav. Popis zákroků, jejich postup, indikace, komplikace a přidružené operace, je uveden v podkapitole 1.3.

1.1 Anatomie lebky

Lebka tvoří mechanickou ochranu pro mozek, dutiny, zrakové, sluchové a rovnovážné ústrojí. Svou anatomí umožňuje pohyb dolní čelisti, která je připojena ke zbytku lebky kloubně, ostatní kosti mají spojení pevné. Pohyb lebky a její napojení na páteř je umožněno prvními krčními obratli specifických tvarů - nosičem (*atlas*) a čepovcem (*axis*). Systematicky se kosti lebky dělí na kosti mozkové části - *neurocrania* a kosti obličejové části lebky - *splanchnocrania*. [20]

1.1.1 Obličejová část lebky

Horní hranici s neurokraniem tvoří kost čichová (*os ethmoidale*), která má tři části - dírkovanou ploténku, čichový labyrint a svislou přepážku. Pod čichovým labyrintem se nachází nosní skořepy (*concha nasalis*).

Dále se k obličejové části lebky řadí párové kosti: patrová, lící a horní čelist. Lící kosti tvoří kostěný podklad tváře a jařmovým obloukem se jejich výběžky napojují na spánkové kosti. Tělo kosti horní čelist (*maxilla*) zahrnuje velkou dutinu *sinus maxillaris*. Výběžky opisují vnitřní a dolní okraj očníce, podpírají tvrdé patro a udávají tvar poloviny zubního oblouku. Dolní čelist (*mandibula*) je tvořena nepárovou kostí, má obloukovitý tvar, ve střední části je rozšířena a jsou na ni uloženy zubní lůžka (*alveoly*). Zrcadlovitě souměrná ramena pokračují až ve výběžek tvořící hlavici čelistního kloubu. [11, 41]

1.1.2 Mozková část lebky

Na neurocraniu se odlišuje klenba lební (*calva*) a spodina lební (*basis cranii*). Calva je ochrannou schránkou pro mozek, její kosti jsou spojeny pomocí švů - šípového, věčitého a lambdového. U novorozence jsou místo švů před konečným srůstem nejprve vazivové pruhy.

V kosti týlní (*os occipitale*) se nachází velký otvor (*foramen magnum*), kterým vede páteřní kanál. Pro skloubení s atlasem slouží kloubní hrboly (*condyli occipitales*). Za tělem kosti týlní je křídlovitý výběžek, zahrnující malá a velká křídla, náležející ke klínové kosti (*os sphenoidale*). V tureckém sedle (*sella turcina*) je uložen podvěsek mozkový (hypofýza). Spánková kost (*os temporale*) je párová kost, kterou tvoří kost skalní (*pars petrosa*) s tvarem pyramidy, šupina kosti spánkové (*pars squamosa*) a bubínková část (*pars tympanica*). Do spánkové kosti je otisknuto ganglium trojklanného nervu. Jejím otvorem také prochází vnitřní zvukovod a dva hlavové nervy.

Na čelní kosti (*os frontale*) rozlišujeme nadočnicové oblouky (*arcus superciliares*), šupinu (*squama frontalis*) a střední části (*pars nasalis*). Přes šev věncový (*sutura coronalis*) na ni navazuje kost temenní (*os parietale*). Jedná se o párové kosti, kdy jsou vzájemně spojené ve švu šípovém (*sutura sagittalis*). [20, 11, 41]

1.2 Zobrazování hlavy pomocí CT modality

Za poslední roky prudce vzrostl počet vyšetření provedených počítačovou tomografií (CT). Díky vývoji techniky se snižuje dávka radiace, kterou je pacient při tomto vyšetření vystaven a zároveň je zkrácena doba snímání. V nemocnicích je nejčastěji CT systém třetí generace, který má rentgenku s vějířovitým svazkem rentgenového záření a velké množství detektorů. Při převozu pacienta po vážné nehodě či jiném úrazu, je nejčastěji provedeno právě CT vyšetření. Důvodem je především jeho rychlost, ale díky dobré prostorové rozlišovací schopnosti má také vysokou informační hodnotu, která může usnadnit rychlé stanovení diagnózy. CT systém tedy oproti klasickému RTG nevytváří pouze sumační obraz, ale zachovává informace o objektech v prostoru. V přidruženém programu může lékař či jiný zdravotnický pracovník nasnímaná data prohlížet buď po jednotlivých řezech (v rovině axiální, frontální i sagitální) nebo si vytvořit 3D model některé z tkání či jejich kombinací. Indikací ke snímání hlavy pomocí CT systému je podezření na fraktury lebky, vnitřní krvácení, otok mozku, podezření na cévní mozkovou příhodu nebo podezření na nádory mozku. Slouží také pro monitorování pooperačních stavů před a po některých neurochirurgických zákrocích. Kontraindikací k tomuto vyšetření bývá gravidita, pouze v případě ohrožení života se přes tento stav vyšetření provede. CT hlavy se provádí buď s nebo bez kontrastní látky. CT s kontrastní látkou se používá především při zjišťování stavu cévního řečiště. Pacientovi je podána kontrastní látka buď nitrožilně nebo ji nějakou dobu před vyšetřením vypije. Nejčastěji se jedná látky obsahující jód, ale u pacientů, kteří na něj mají alergii, se aplikují neiodické látky. Softwary ovládající CT systém jsou vybaveny snímacími protokoly, díky nimž získáme data pouze pro zájmovou oblast a minimalizujeme zátěž pacienta podle principu ALARA.

1.2.1 Princip CT

Systémy založené na počítačové tomografii provádí nejprve akvizici a poté rekonstrukci z nasnímaných projekcí. Akvizice je dosaženo vysíláním rentgenového záření na sledovaný objekt a následným detekováním prošlých a utlumených RTG paprsků. Zdrojem záření je rentgenka, která u systémů třetí generace vyzařuje vějířovitě (je třeba do výpočtů, oproti planárnímu vyzařování, zahrnout ještě úhel pod kterým paprsky dopadají). Rentgenka a detektory se kolem pacienta otáčejí a po každém pootočení systému je sejmuta projekce (soubor aproximací paprskových integrálů). Soubor projekcí při spojitém úhlu natočení se nazývá Radonova transformace (RT), která se vizualizuje pomocí sinogramu, kde jsou vykresleny projekce v závislosti na posunech rentgenky - detektoru (horizontální osa) a úhlu natočení (vertikální osa). [7, 13]

Útlum záření při průchodu snímaným objektem je popsán pomocí lineárního součinitele útlumu, který je důležitým parametrem pro výpočet tzv. Housfieldovy jednotky (HU). Ta slouží pro popis denzity (míry zeslabení), ve výsledném obraze jsou její hodnoty zakódovány do jasových hodnot pixelů. Například kostní tkáň má HU rovnu zhruba 3000, díky čemuž je reprezentována jednou z nejvyšších jasových hodnot v obraze. Podle [13] se výpočet Housfieldova čísla realizuje následující rovnicí:

$$HU = K \cdot \frac{\mu_{tkáň} - \mu_{voda}}{\mu_{voda}}, \quad (1.1)$$

kde ($\mu_{tkáň}$) resp. (μ_{voda}) jsou lineární součinitele útlumu tkáně resp. vody a K je tzv. kontrastní faktor, který se vztahuje na CT číslo a udává přesnost měření. Za K a (μ_{voda}) se obvykle dosazují hodnoty 1000 a $0,19 \text{ cm}^{-1}$. [13, 7]

Existuje několik způsobů získání rekonstruovaného obrazu z projekcí. Dlouhou dobu byla nejpoužívanější metodou filtrovaná zpětná projekce, založená na rozložení jednorozměrných projekcí do rekonstrukčního obrazu pod stejným úhlem, pod jakým byly sejmuty, za současného využití jednorozměrného filtru pro zlepšení výstupu rekonstrukce. [22]

V současné době je díky vývoji výpočetní techniky zaznamenán návrat k iteračním řešením, které jako metody rekonstrukce dosahují výborné kvality rekonstruovaných obrazů. Rekonstrukční algoritmy si vývojové firmy chrání a je málo informací o jejich přesném fungování. Dají se rozdělit na čistě iterativní, statistické a modelově orientované metody. [50, 4, 51]

1.3 Dekompresivní operace

Jedním ze závažných projevů poškození mozku je mozkový edém, který je jen součástí sledu navzájem propojených patologických procesů. Jedná se o stav zvýšeného

shromažďování tekutiny uvnitř nebo vně mozkové tkáně. Nejprve dojde k narušení iontové homeostázy, poté autoregulace a bez včasného zásahu může skončit ischemickým poškozením mozku. Současná medicína rozlišuje několik typů mozkového edému, jejich hranice však nejsou striktně vymezeny a během patologických procesů může docházet k přechodům mezi nimi. Edém způsobuje zvyšování nitrolebního tlaku, což může vést až k herniaci mozkové tkáně (posunutí do netypické či neanatomické pozice). [24, 18]

Řešení velké škály navzájem souvisejících projevů jsou obecně rozděleny na konzervativní a operativní. Při rozhodování, který z přístupů je pro pacienta vhodnější, lékaři monitorují několik nitrolebních parametrů. Klasické neurologické vyšetření má často zkreslený výsledek nebo je úplně znemožněné v případě, kdy jsou pacienti uvedeni do farmakologického kómatu. Informace o aktuálním stavu poskytne CT vyšetření, měření aktuálního nitrolebního tlaku, mozkového perfúzního tlaku a další veličiny. Mezi nejvýznamnější neurochirurgické operativní postupy patří dekompresivní kraniotomie a kraniektomie. [24]

1.3.1 Dekompresivní kraniotomie

Tento operační postup se využívá pokud není otok mozku příliš velký a nepředpokládá se jeho další zvětšování. Samotná kraniotomie se provádí také při operaci nádoru mozku, zastavení a odsátí krvácení atd. Rozdílné kroky má dekompresivní kraniotomie a kraniektomie až téměř na konci zákroku (podrobný postup společného začátku operace bude popsán v části 1.3.2). Rozdíl je v tom, že u dekompresivní kraniotomie zůstane vyříznutá část lebeční kosti po zašití kůže uvnitř, je tam však nepripevněná, fixace je zajištěna pouze sešitím spánkového svalu s fascií temporalis. Umožnění pohybu kostní ploténky zabezpečuje přizpůsobení velikosti otoku. [36, 35, 37]

1.3.2 Dekompresivní kraniektomie

Při masivním otoku mozku, kdy hrozí v důsledku ischemie mozková smrt, se volí operační postup dekompresivní kraniektomie (DK). Je to neurochirurgická operace kompenzující patologicky vysoký nitrolební tlak a zajišťující dostatečnou perfúzi tkáně zvýšením perfúzního tlaku tím, že odstraní část lebeční klenby a zvětší objem nitrolebeční dutiny. Četné studie uvádějí, že velká kraniektomie je pro pacienty prospěšnější než malá, k provedení malé kraniektomie dochází pokud byla původně operačním plánem kraniotomie, ale v průběhu zákroku bylo rozhodnutí změněno, odstraněná plocha se již nezvětšuje. Rozlišují se 3 základní typy DK: jednostranná, oboustranná a bifrontální; přičemž oboustranná DK je nejméně častá. Jednostranná

DK může být buď pravostranná nebo levostranná, její plocha se obvykle pohybuje v rozmezí 130-160 cm². Bifrontální DK zabírá zpravidla větší plochu, přibližně okolo 200 cm². [24, 35]


Postup operace

U neurochirurgických operací je důležitá příprava - jak podrobné plánování zákroku lékaři, tak příprava pacienta na operačním sále. Hlava musí být zafixována pomocí trojbodového uchycení držáků, na oholenou část lebky je zakresleno, kudy povede kožní řez. Pro přístup k lebeční kosti musí být odklopen lalok tvořený vrstvou kůže, svalů a prokrvenou blánou kryjící kost (*periostem*). Blízko okraje kožního řezu jsou provedeny návrty lebky, přes které je poté odloučena tvrdá plena mozková (*dura*). Její odloučení od kosti je důležité kvůli riziku jejího poškození, které by bylo provázeno vážnými pooperačními komplikacemi. Mezi návrty je následně veden řez kostí pomocí speciálního nástroje kranionože a kostní ploténka může být poté vyjmuta. Dalším důležitým krokem je chirurgické otevření tvrdé mozkové pleny neboli durotomie, po které může být dura odklopená a chirurg může provést potřebné úkony jako vyplachování, odsávání, koagulace krvácení atd. Při sešívání dury a periostu se vytvoří prostor pro expanzi mozkové tkáně. Po zavedení podtlakové drenáže jsou všechny vrstvy zašity. [24, 35]

Odebraná kostní ploténka je zaslána do tkáňové banky, kde je podchlazená při teplotě uváděné v rozmezí -16 až -80 °C uchována pro případnou pozdější kranioplastiku (dále existuje alternativa s voperováním explantované kosti do podkožního tuku v podbřišku pacienta). Pacient je po operaci uměle ventilován a tlumen pomocí léků (u některých pacientů je vhodná i hypotermie). Přes čidlo je sledován tlak v lebce a jsou prováděny kontrolní CT vyšetření (příklad na obrázku 1.1), v případě potřeby vyšetření pomocí magnetické rezonance. [17, 24, 35]

Indikace

Rozlišuje se dekompresivní kraniektomie primární a sekundární. Primární DK je akutní, provádí se do 24 hodin po úrazu, naproti tomu k sekundární DK se přistupuje pokud dojde ke zhoršení stavu nebo nezabírá konzervativní léčba. [24] GCS (Glasgow Coma Scale) je stupnice používaná pro určení stavu vědomí a pokud je její hodnota mezi třemi a osmi body, znamená to závažnou poruchu vědomí. Jako další indikační kritérium je ověřován stav zornic - pokud jedna nebo obě zornice nereagují během prvního dne po úrazu. Na snímcích z CT se dále sleduje a za nutně operabilní se pokládá nález hyperintenzivní léze nad prahový objem, příliš velký posun střední čáry a stlačení nebo ucpání bazálních cisteren a postranních mozkových komor. Dalším kritériem je vysoký perfúzní tlak v mozku, který se nepodařilo snížit ani



Obr. 1.1: Kontrolní CT snímky po provedené kraniektomii od dvou různých pacientů. Oba snímky zachycují edém mozkové tkáně po jednostranné kraniektomii. [49, 1]

intenzivní farmakologickou léčbu. Během operace mozku se k primární DK přistoupí pokud vznikne edém, který přesahuje chirurgicky otevřenou duru. [25]


I přes to, že nebylo nutné provést DK během prvních 24 hodin, je nutné sledovat vývoj pacientova stavu a jeho reakce na medikaci. Sekundární DK musí být provedena pokud se pacient na bodové stupnici GSC přesunul do kategorie závažné poruchy vědomí, zhoršil se nález na kontrolním CT, ustaly reakce zornice, na CT jsou viditelné projevy ischemie mozkové tkáně nebo byly zaznamenány negativní změny intrakraniálního nebo mozkového perfúzního tlaku. [24, 21]

Lékaři rozhodují na základě více indikačních kritérií, pouze v případě sledování pooperačního stavu je k DK přistoupeno i základě jednoho kritéria. [24]

1.3.3 Kranioplastika

Nejčastěji prováděnou operací po dekompresivní kraniektomii je kranioplastika, která spočívá ve vyplnění chybějící části lebky implantátem (obrázek 1.2). Může se jednat o implantát autologní (původní vyjmutá kost) nebo umělý. Plastika obnoví kompletní mechanickou ochranu mozku, také má velký význam pro psychiku pacienta. Vhodný čas pro rekonstrukci klenby lebky je u každého pacienta individuální a záleží na několika faktorech. Obecně se lékaři snaží provést rekonstrukci klenby lebeční v co nejkratší době, ale pacient musí mít zahojenou ránu po první operaci, aby nedošlo k jejímu poškození, a velice důležitý je jeho aktuální zdravotní stav. Provedení

kranioplastiky je podmíněno kontrolou stavu mozkové tkáně na CT snímcích, ale také pacient nesmí mít žádné další vážné zdravotní komplikace (i jiného než neurologického původu), které by představovaly příliš velké riziko fatálních následků. Plastika se obvykle provádí v období do 1,5 roku od DK (průměrně 5 měsíců). V některých případech se na odstranění faktorů bránících implantaci čeká i několik let nebo je implantace vyloučená zcela, tehdy je mechanická ochrana zajištěna speciální helmou. [24, 39]



Obr. 1.2: Na obrázku je vizualizace kranioplastiky s využitím umělého implantátu. [18]

Syndrom propadlé kůže

Syndrom propadlé kůže je popisován zvláště u pacientů, kterým byla provedena implantace kosti nebo náhrady déle než 3 měsíce po DK. Jak je vidět na obrázku 1.3, jedná se o vklenutí kůže, kdy je působením tlaku okolního vzduchu tlačeno na mozkovou tkáň. Tento jev může způsobit problémy s koordinací pohybů, změny ve vnímání, pískání v uších, poruchy centra řeči, lehkou formu ochrnutí poloviny těla a problémy s pamětí. Důsledky syndromu propadlé kůže jsou téměř vždy odstraněny kranioplastikou, u malého procenta pacientů se již implantací lebečního krytu symptomy neodstraní. [24, 21]

Druhy implantátů

Nejlevnější varianta kranioplastiky je za použití autologního implantátu - vlastní kostní ploténky. Jak už bylo zmíněno v části 1.3.2, deponovaná ploténka může být umístěna ve tkáňové bance nebo zašita do pacientova podkoží břicha. Před reimplantací někteří lékaři navrtají do kosti ještě několik dírek, čímž provedou opatření



Obr. 1.3: Příklady syndromu propadlé kůže, vlevo při pohledu ze předu na jednostrannou DK a vpravo při pohledu z boku na bifrontální DK. [23, 12]

proti vzniku epidurálního hematomu. [24, 21, 17] Reimplantovaná kost se připevňuje pomocí drážek a šroubů nebo pomocí kostních švů, pokud dojde v pooperačním období k narušení fixace, je nutná revize. Mezi nejčastější pooperační komplikace patří infekce a osteoresorpce kostní ploténky, kdy může dojít až k nutnosti výměny za neautologní implantát. Dalším z důvodů reoperace a výměny za vyrobený implantát bývá estetika, kdy umělý implantát vykazuje v některých případech pro pacienta uspokojivější a přirozenější vzhled. [21, 17]

Pokud je autologní implantát poškozený nebo byl označený za nevhodný pro reimplantaci, je pacientovi implantován umělý. Pro bojové podmínky jsou v článku [32] popisovány postupy vytvoření náhrady podle modelu hlavy, který byl využíván pro nastavení stereotaktické navigace, s minimální individuální úpravou, ale mimo tyto ztížené podmínky a omezené možnosti je už běžnou praxí pacientovi za pomoci CT zařízení, 3D tiskárny a vyspělých softwarů vytvořit implantát přímo na míru. Díky takovému implantátu je dosaženo výborné estetické úrovně a může být výrazně zkrácena doba provedení kranioplastické operace. Individuální model se vždy vytváří na základě snímků z CT, na 3D tiskárně se vytiskne část modelu a použije se jako odlévací forma pro implantát nebo dojde k tisku implantátu přímo. [34, 12]


Pomocí 3D tiskáren se, díky rozšíření tisku i jinými než plastovými materiály, dá vyrobit například titanový implantát (obrázek 1.4). [27]

Další možností je implantát z polyethylenu nebo polyetherketonových vláken (PEEK materiál), který je vidět na obrázku 1.5. Ve své době způsobil přelom biokeramický hydroxiapatit (obrázek 1.5), který je svým složením blízky skutečné kosti a bylo prokázáno, že iniciuje tvorbu nových kostních buněk. [3, 53, 38]

Každý z materiálů má své výhody a nevýhody a výběr musí být přizpůsoben potřebám pacienta. Jsou zaznamenány případy, kdy pacientův organismus implantát nepřijal a musela být zvolena jiná forma náhrady. [3, 21]



Obr. 1.4: Ukázka implantátu z titanové mřížky. [29]



Obr. 1.5: Ukázky implantátů vyrobených z PEEK vláken (vlevo) a hydroxyapatitu (vpravo). [46, 52]

2 Segmentace

Segmentace obrazu se řadí k technikám analýzy obrazu a jejím výsledkem je tedy popis původního obrazu. Jedná se o úplné rozdělení na podoblasti podle obsahového kontextu, kdy se jednotlivé segmenty nepřekrývají. Při segmentaci do dvou kategorií (objekt a pozadí) se používá označení binární segmentace, pro vyšší stupeň členění se jedná o víceúrovňové segmentování. Pro provedení existuje velké množství technik, zařazených do několika skupin. [22]

2.1 Klasické segmentační přístupy

První oblastí je segmentace podle homogenity oblastí vzhledem ke skalárnímu nebo vektorovému parametru. Na základě skalárního parametru se provádí prahování, jsou zde zařazeny všechny jeho formy - prosté, dvojité, adaptivní i poloprahování. Vektorový parametr je posuzován za pomoci 2D sdruženého histogramu (dvousložkový parametr), vícesložkového parametru nebo adaptivního prahování na základě vícerozměrných histogramů. [22, 44]

Další ze segmentačních přístupů je regionově orientovaný. Prvním z typických zástupců této kategorie je narůstání oblastí, jedná se o metodu, kdy je určena pozice semínka (*seed*), ze kterého se na základě rozhodovacích kritérií vyvine segmentovaná oblast. Podle podobnosti oblastí se provádí segmentace metodou slučování, kdy je obraz nejprve rozdělen na elementární oblasti a na základě statického nebo dynamického kritéria jsou sousední oblasti spojovány do větších celků. Posledním zástupcem regionově orientovaných metod je dělení a spojování oblastí. V první fázi se podle kritérií každá nehomogenní oblast musí rozdělit na menší, v bodě, kdy jsou všechny podoblasti homogenní začíná druhá fáze, ve které se spojí všechny sousední podobné kvadranty. [22]

Segmentace založená na hledání hran je nejjednodušeji provedena vytvořením hrubé hranové reprezentace a její následnou úpravou (odstranění falešných, propojování a ztenčování hran). K vytvoření hrubé hranové reprezentace je možné použít například směrových masek, masky Laplaciánu s detektory průchodu nulou, Cannyho detektor atd. Další z metod hledání hranic objektů je Houghova transformace, kdy se hledá křivka o předem známém tvaru, využívá se při tom parametrického prostoru. Obtížnost metody je závislá na tvaru zvolené křivky, čím více má její rovnice parametrů, tím bude složitější. Hledání hranic sledováním hran se zaměřuje na sledování čtyřokolí nebo osmiokolí počátečního, zvoleného bodu. V prohledávaném okolí musí daný pixel splňovat kritérium podobnosti, aby byl označen za hraniční. [22, 44]

Na pomezí hranově a regionově orientovaných přístupů je metoda rozvodí (*watershed*). Výsledky segmentace jsou ovlivněny vhodnou volbou parametrického obrazu. Hranice segmentů (rozvodí) tvoří v parametrickém obraze vrcholy reliéfu. [22, 44]

Metody pružných a aktivních kontur řadíme k optimalizačním přístupům. Při použití aktivních kontur musíme předem znát tvar požadovaného útvaru, vytvořit průměrnou konturu a pomocí metody hlavních komponent (PCA) je zkoumána její odlišnost od konkrétních kontur. Pružné kontury jsou buď parametrické nebo geometrické. Parametrické pružné kontury mají na začátku nastavený určitý tvar křivky, který se podle působení vnějších a vnitřních sil mění, hranice objektu je stanovena po tom, co nastane rovnováha sil. U geometrických kontur je jejich definice dána vrstevnicemi implicitně zadané funkce (*level-set metoda*), jedna křivka může být v průběhu optimalizace rozdělena na části, které se následně mohou zase spojit. Vývoj kontur je dán výpočtem parciální diferenciální rovnice. [22]

2.2 Využití strojového učení pro segmentaci

Odlišným přístup k segmentaci je s využitím strojového učení. Všechny předchozí metody zahrnovaly předem stanovená pravidla nebo principy, na základě kterých byl ze vstupních dat vytvořen segmentovaný obraz. Strojové učení naopak pravidla vytváří podle konkrétního problému na základě dat na vstupu a většinou i na předložených požadovaných výstupů segmentace. [44, 9]

Podle způsobu trénování se rozlišuje učení s učitelem (*supervised learning*), bez učitele (*unsupervised learning*), samořízené (*self-supervised learning*) a posilované (*reinforcement learning*). Nejběžnější je učení s učitelem, kdy se modelu při trénování předkládají data a jejich požadovaný výstup (anotace provedená nejčastěji odborníkem v dané oblasti), časté využití nachází pro segmentaci, detekci a další aplikace. Specifickým případem a zároveň dalším způsobem trénování je samořízené učení, kdy anotaci neprovádí člověk, ale dojde k jejímu generování pomocí heuristického algoritmu. Učení bez učitele dopředu nezná správné výstupy, jedná se o samoorganizaci charakteristik dat na vstupu. Využívá se nejčastěji pro redukci dimenzionality nebo shlukování. Posledním ze zmíněných způsobů je posilované učení, které je založeno na postupném získávání informací a zlepšování se na základě zpětné odezvy. Základní jednotkou je zde agent, který se snaží maximalizovat odměnu za správně provedenou interakci s prostředím. [5, 9]

Učení pouze jedné či dvou vrstev reprezentací dat se nazývá mělké učení (*shallow learning*), více vrstev, nejčastěji desítky až stovky, využívá hluboké učení (*deep learning*). [9]

2.2.1 Hluboké učení

Velkým a významným odvětvím strojového učení je hluboké učení, které se zabývá postupnou reprezentací dat po hierarchicky uspořádaných vrstvách. Jde o zcela automatickou extrakci příznaků, postupně od nejvíc obecných až po nejdetailnější. Tento způsob získávání příznaků se osvědčil jako efektivnější pro stroj v porovnání s tím, do kterého zasahoval člověk. Počet vrstev modelu se označuje jako hloubka. V tomto odvětví se pro modely s velkým množstvím vrstev využívají neuronové sítě. V procesu učení se hledají parametry vrstev - váhy, které transformují vstupní data na reprezentaci odpovídající požadovanému cíli. Učení probíhá v několika epochách, což je označení pro stav, kdy model síť prošel všechny trénovací data. Po každé dokončené epoše (běhu) nebo jejich sérii se provádí vyhodnocení, jak dobře model data umí mapovat v porovnání s referencí, pomocí ztrátové funkce (*loss function*). Ztrátové skóre (*loss score*) je jako výstup ztrátové funkce optimalizátorem, zahrnujícím algoritmus zpětného šíření (*backpropagation algorithm*), převedeno na informaci o úpravě jednotlivých vah tak, aby došlo ke snížení skóre v další iteraci či epoše. Iterativně tato optimalizace probíhá do splnění ukončujících podmínek (stanovený počet iterací nebo minimální hodnota skóre).

2.3 Konvoluční neuronové sítě

Konvoluční neuronové sítě (CNN) jsou dnes nejvyužívanější skupinou neuronových sítí pro zpracování a analýzu obrazů. V mnohých aspektech se CNN podobají klasickým neuronovým sítím, mají ale odlišnou strukturu vzájemného propojování vrstev, přičemž některé z nich jsou pro CNN specifické a v architektuře klasických sítí se nevyskytují. Díky vzniku konvolučních neuronových sítí mohlo dojít k řešení složitějších problémů. Na rozdíl od klasické dopředné architektury, kdy byl každý prvek vrstvy spojen se všemi prvky v předchozí, jsou u CNN propojení s předchozí vrstvou jen v lokální oblasti o stanovené velikosti. Tato odlišnost zásadním způsobem ovlivňuje počet vah (trénovatelných parametrů) a složitost problému. Váhy konvolučních neuronových sítí jsou navíc vzájemně sdílené a uloženy v tzv. jádru (*kernel*).


Základními strukturními prvky všech neuronových sítí jsou umělé neurony, které jsou uspořádané do vrstev, mezi kterými jsou daným způsobem vytvořeny spoje. Konkrétně u CNN je neuron spojen s několika neurony předchozí vrstvy. Nejznámější model umělého neuronu se nazývá perceptron, obsahuje vedení vstupních hodnot, které jsou násobeny příslušnými vahami, následně dojde v těle perceptronu k odečtení prahu a k sumaci modifikovaných vstupních dat. Na výstup je dána odezva perceptronu na aktivační funkci (charakteristiku neuronu), která se značí $f(\alpha)$, kde α je aktivace neuronu. Existuje velké množství druhů aktivačních funkcí, nejjednodušší je

skoková funkce (Heavisideova funkce nebo signum), dále se používá například sigmoida nebo lineární funkce. Pro konvoluční neuronové sítě se ale nejčastěji volí některá modifikace funkce Rectified Linear Unit (ReLU). Pro základní variantu ReLU platí, že hodnoty α menší než nula jsou převedeny na nulu a naopak pro α větší je výstup aktivační funkce zachován shodný jako vstup (grafické zobrazení na obrázku 2.1). Modifikace spočívají například v posunu bodu zlomu po x-ové ose nebo v malém nenulovém průchodu i když hodnota α nedostačuje prahu pro aktivaci (tzv. Leaky ReLU). [26]

Rovnice základní varianty ReLU má dle [26] tvar:

$$f(\alpha) = \max(0, \alpha), \quad (2.1)$$

kde $f(\alpha)$ je výstupní hodnota aktivační funkce a α je aktivace.



Obr. 2.1: Graf funkce ReLU podle rovnice 2.1.

2.3.1 Architektura

Jak již bylo zmíněno v úvodu kapitoly 2.3, CNN obsahují kromě klasických také pro tuto skupinu sítí specifické vrstvy. Mezi specifické se řadí především vrstva konvoluční (*convolutional layer*), dále pak podvzorkovací (*pooling layer*), plně propojená (*fully-connected layer*) a tzv. dropout.

Konvoluční vrstva

Základní operací této vrstvy je diskretní konvoluce. Konvoluční vrstva je složená z množství filtrů (*kernels*), které tvoří základní jednotky architektury CNN. Rozměr filtru v první konvoluční vrstvě odpovídá $h \times w \times d$, kde h je výška vstupního obrazu, w jeho šířka a d odpovídá počtu kanálů obrazu (u barevných se rovná 3, u šedotónových odpovídá 1).

Parametr *receptive field* definuje propojení dvou po sobě jdoucích vrstev, kdy se využívá redukce počtu parametrů díky spojení neuronu jen s určitou oblastí v předchozí vrstvě, nedochází k propojení každého s každým. Redukce parametrů je umožněna díky sdílení parametrů - postavené na předpokladu invariantnosti pozice pro výpočet příznaku. Sdílení parametrů je výhodou i při zpětné úpravě vah, kdy není upravována každá váha zvlášť, ale změny jsou aplikovány na celou skupinu sdružených vah. Počet konvolučních vrstev uspořádaných za sebou, kdy výstup jedné je vstup pro následující, se označuje jako hloubka neboli *depth*. Neurony zaměřující se na stejnou podoblast vstupních dat se označují jako tzv. *depth column* neboli hloubkový sloupec.

Krok (*stride*) je dalším důležitým parametrem, který určuje o kolik prvků se během výpočtu konvoluční jádro posouvá, a jeho hodnota je závislá na velikosti konvolučního jádra. Průchod masky přes obraz může být realizován s nebo bez překryvu.


V konvolučních blocích dochází k nežádoucímu přechodovému jevu, kdy se výstupy vrstev postupně zmenšují a pro zachování původní výšky a šířky obrazu po průchodu filtrem je využita kompenzace v podobě doplnění nulami - operace *zero-padding*. Původní obraz je doplněn na okrajích takovým množstvím nul, aby po průchodu masky filtru zůstaly zachovány nezměněné rozměry.

Pooling vrstva

Pooling (podvzorkovací) vrstva se v CNN architektuře umísťuje za vrstvu konvoluční. Díky ní je dosaženo nižší výpočetní náročnosti a redukuje se počet parametrů. Princip je založený na průchodu okna o malé zvolené velikosti, přičemž se volí varianta procházení s překryvem nebo bez překryvu. V aktuálním okně se provede podvzorkování vnitřní reprezentace podle vybrané operace, kterou může být například výběr maxima, minima nebo průměrování. Nejčastěji se vyskytuje tzv. max pooling, využívající hledání maxima v procházejícím okně. Při zvolení operace max, jako na obrázku 2.2, je podvzorkování založené na tom, že se do výstupní matice dostane pouze maximum z prvků aktuálního podokna. [26]

Plně propojená vrstva

Plně propojená vrstva (*fully-connected layer*) bývá umístěna u konvolučních neuronových sítí na konci a často se jich vyskytuje více za sebou. Všechny neurony této vrstvy jsou spojeny se všemi v předchozí vrstvě. Konečný výstup sítě se může dále upravit, pro klasifikační úlohy například za využití funkce *softmax*, která pro každou třídu určí pravděpodobnost, s jakou do ní vstupní data patří. Příslušnost k určité kategorii je v rozmezí od 0 do 1. Vektor výstupních hodnot pro daný vzorek obsahuje



Obr. 2.2: Princip max pooling vrstvy. V části a) je vstupní matice, kde jsou barevně vyznačeny průchody okna s rozměrem 3×3 a krokem 3, tedy bez překryvu. Z číselných hodnot matice v aktuálním okně se vybere maximum, které se uloží na odpovídající pozici výstupu. V části b) je zaznamenán výstup max pooling vrstvy pro jednotlivé pozice okna.

příslušnosti k jednotlivých klasifikačním třídám a jeho suma musí být 1. Výpočet lze realizovat podle rovnice 2.2. [15]

$$f(x)_i = \frac{e^{x_i}}{\sum_{n=1}^N e^{x_n}}, i = 1, \dots, N, \quad (2.2)$$

kde x je vstupní vektor, $f(x)$ výstupní vektor příslušností ke třídám a N je počet klasifikačních kategorií. Pro binární klasifikaci se častěji používá místo softmax sigmoida.

Dropout vrstva

Dropout je regularizační metoda, která může ve formě vrstvy CNN předcházet přeučení. Princip je založený na nastavení aktivace některých neuronů hluboké vrstvy na nulu, dochází tedy k deaktivaci některého neuronu. Nenastavuje se počet neaktivních prvků, ale pravděpodobnost, s kterou budou deaktivovány. Vynechání některých neuronů se děje pouze při trénování, během testování jsou všechny neurony aktivované, váhy jsou násobené, v předchozím kroku použitou, pravděpodobností. Zmíněným postupem tedy v každé epoše získáme jinou architekturu a díky tomu by mělo být dosaženo lepší generalizační schopnosti sítě. [45]

2.3.2 Trénovací algoritmy

Pro optimalizaci parametrů sítě se využívá některý z trénovacích algoritmů, za pomoci kterého se snažíme minimalizovat hodnoty ztrátových funkcí. Základním algoritmem je stochastický gradientní sestup (SGD), který je vylepšenou verzí metody gradientního sestupu (GD) nevhodné pro objemnější problémy. SGD upravuje váhy

po každé iteraci, tedy po představení každého vzorku. Výhodou je, že se algoritmus nezastaví u falešně optimálního lokálního minima. [9, 6]

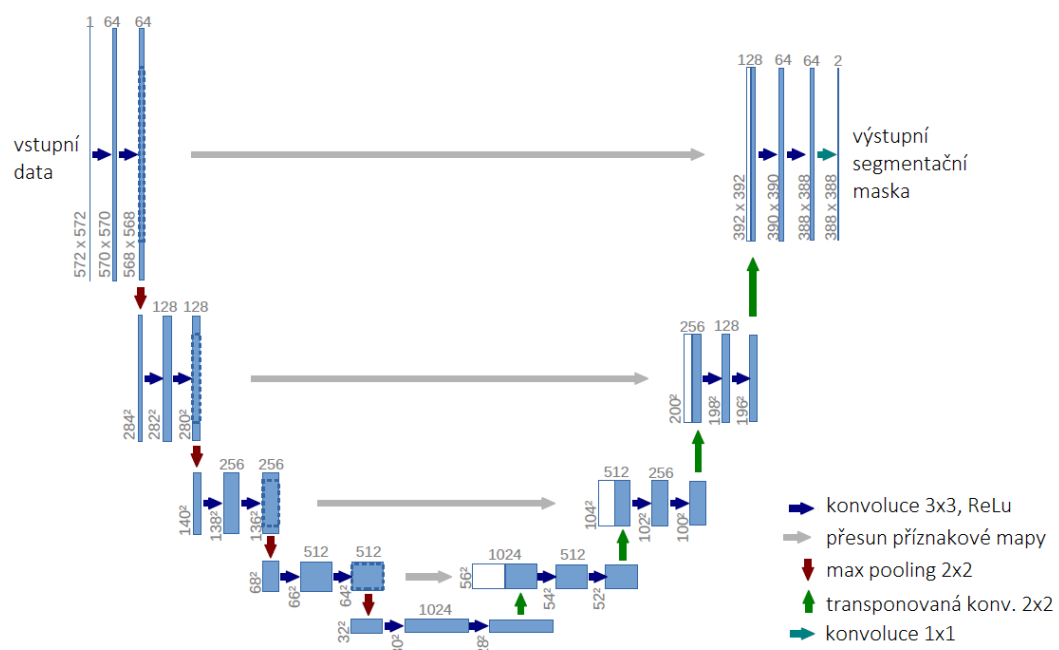
Nejpoužívanějším algoritmem je dnes ADAM (*Adaptive moment estimation*), který byl speciálně navržen pro hluboké sítě. Jedná se o kombinaci metod RMSprop a SGD s hybností. Adam využívá adaptivní učící krok, odlišné pro různé parametry. Algoritmus počítá s průměrem gradientu několika vzorků (tzv. mini-batch) a také pracuje s parametrem beta pro postupné zapomínání. [16]

2.3.3 Segmentační architektury

Velký průlom v oblasti konvolučních neuronových sítí byl zaznamenán díky síti AlexNet navržené skupinou autorů v jejímž čela stál Alex Krizhevsky. Dalším vývojem vznikali složitější a hlubší sítě a mohly být využity pro složitější problémy. Mezi nejvýznamnější patří VGG-16, ResNet, GoogleNet, MobilNet a další jejich modifikace. [2] V současnosti je velice populární architektura Segnet a U-Net, které jsou založené na principu enkodéru a dekodéru a existují v mnoha modifikacích.

U-Net

U-Net byla původně určena pro segmentaci medicínských dat, konkrétně buněk, ale našla široké využití i v jiných oblastech. Na obrázku 2.3 je její základní architektura. Opticky je rozdělena na sestupnou a vzestupnou část a tvoří ji pět úrovní. Každá sestupná (kontraktilní) úroveň je složená ze tří konvolučních vrstev s filtrem velikosti 3×3 , následovaných vždy ReLU a nakonec pooling vrstvou provádějící operaci max s oknem 2×2 a krokem 2, díky které dojde k podvzorkování a zmenšení vstupních dat na polovinu. Zároveň dojde k vytvoření kopie mapy příznaků, která je poslána na odpovídající úroveň vzestupné části. Při průchodu do další úrovně je vždy dosaženo zmenšení výšky a šířky příznakové mapy za současného zvětšování její hloubky. Vzestupná (expanzivní) část využívá v přechodech mezi úrovněmi transponovanou konvoluci s filtry o velikosti 2×2 , díky které dojde k nadvzorkování (up-sampling). K převzorkovaným mapám je připojen výřez příznakového pole z odpovídající úrovně sestupné části. Takto rozšířenou mapu dáme na vstup dvou po sobě jdoucích konvolučních vrstev (vždy následovaných ReLU) s maskou 3×3 . V poslední úrovni je za druhou ReLU aktivaci zařazena ještě 1×1 konvoluce, před závěrečným určením klasifikační třídy díky tomuto bloku dojde k redukci příznaků. Snížení počtu příznaků je umožněno díky konvolování přes hloubku, kdy je na výstupu získána jejich lineární kombinace. [42]



Obr. 2.3: Základní architektura U-Net. Obdélníkové bloky reprezentují mapy příznaků, ty označené bílou barvou jsou zkopírované příznaky, které jsou přeneseny do vzestupné větve. [42]

3 Předchozí práce

Segmentaci lidské lebky pomocí konvolučních neuronových sítí se zabýval výzkumný tým z Amsterdamu. Autoři Jordi Minnema, Maureen van Eijnatten a kol. ve svém článku [33] pracovali s daty od dvaceti pacientů po kraniektomii a kranioplastice nasnímaných na šesti různých CT systémech. Pro učení s učitelem využili odborníky určené zlaté standardy. Nasnímaná data byla nejprve normalizovaná tak, aby hodnota intenzity voxelu byla v intervalu od nuly do jedné. Následně byly náhodně generovány výseky o velikosti 33x33 pixelů, které byly využity jako vstupní data pro učení. V jejich práci je také popisován problém s výtěžností dat, jen malá část voxelů bude využita pro učení oproti jeho celkovému počtu. Pro svůj projekt vybrali konvoluční neuronovou síť navrženou pro segmentaci tumoru v datech z magnetické rezonance a modifikovali ji tak, aby na vstup mohly být dány CT data s označením pouze dvou kategorií - kost a pozadí (oproti původním 5 třídám). Stejnou modifikaci provedli i u výstupního klasifikátoru. Architektura sítě byla založena na 4 blocích po 4 vrstvách, všechny první v každém bloku byly konvoluční se sadou různě velkých jader, po ní následovaly vždy vrstvy aktivační - ReLU. Tímto postupem chtěli zajistit flexibilitu při detekci. Další v pořadí byly vrstvy pro normalizaci a každý blok zakončila pooling vrstva. Vyhodnocení a srovnání výsledků predikce a zlatého standardu probíhalo v klasifikační vrstvě, která byla v architektuře zařazena za čtyři výše popsané bloky. Pro závěrečné testování byly k dispozici data pouze 2 pacientů, protože pro vytvoření datové sady bylo vybráno schéma *leave-2-out*, podle kterého jsou pro tvorbu trénovací sady využity data 18 pacientů a zbylé dva se dají bokem pro pozdější testování. Výstup sítě byl převeden na STL (Standard Triangle Language) model, aby mohl být porovnán se zlatým standardem uloženým v tomto formátu, který popisuje geometrii povrchu 3D objektu. Byla zaznamenána odchylka v rozsahu -5 až +5 mm. Úspěšnost testování byla vypočítána pomocí koeficientu podobnosti DSC (dice similarity coefficient), který je definován jako podíl dvojnásobku počtu správně pozitivních a součtu falešně negativních, falešně pozitivních a dvojnásobku správně pozitivních pixelů. Průměrná hodnota DSC obou testovacích pacientů byla stanovena na 0,92 se směrodatnou odchylkou 0,04.

Využitím konvolučních neuronových sítí, konkrétně U-Net, pro segmentaci biomedicínských obrazů se zabývali v publikaci [42] autoři Olaf Ronneberger a kol., kteří v rámci soutěže ISBI síť aplikovali pro segmentaci struktur na snímcích z mikroskopu. Síť pracuje vždy s lokálním regionem (patch) nikoliv s celým snímkem naráz. Jednou z modifikací autorů je v podvzorkovací části velké množství příznakových kanálů předávajících informace vrstvám s vyšším rozlišením. Architektura sítě byla rozdělena na redukční a expanzivní část. Redukční oblast se skládala z opakujících se bloků 3x3 konvoluce (unpadded konvoluce), za kterou následovala ReLU vrstva a 2x2

max pooling operací pro dosažení podvzorkování. V každém podvzorkovacím kroce dochází ke zdvojnásobení počtu příznakových vedení, poté v expanzivní oblasti převzorkování příznakové mapy a 2x2 konvoluce (up-convolution), po které následuje konkaténace s korespondující příznakovou mapou z redukční části, 3x3 konvoluce a ReLU vrstvy. Celkem měla síť 23 konvolučních vrstev a nebyly použity žádné plně propojené vrstvy. Augmentací bylo docíleno robustnosti vůči transformacím posunu a rotace, deformacím tvaru a změnám jasových hodnot. Síť byla vyzkoušena na různých problémech s odlišným původem dat. Nejprve síť využili při segmentaci struktur v snímcích z elektronového mikroskopu a výsledek popsali metrikou *warping error* (která toleruje nesouhlasné hraniční oblasti objektu) s hodnotou 0,00035. Dále byla síť využita pro segmentaci snímků ze světelného mikroskopu na dvou různých datasetech. První dataset obsahoval snímky glioblastom-astrocytomy U373 buněk na polyakrylimidovém substrátu. Snímky byly pořízeny za použití mikroskopování s fázovým kontrastem a pro trénovací sadu stačilo 35 obrazů. Úspěšnost byla stanovena pomocí metriky IOU (*intersection over union*) na 92%. IOU se vypočítá jako podíl průniku a sjednocení oblastí označených ručně a určených segmentací. Druhý dataset obsahoval 20 snímků s HeLa buňkami nasnímanými pomocí diferenciálního interferenčního kontrastu, po zhodnocení byla hodnota IOU 77,5 %.

V článku [2] skupina autorů v čele s Md Zahangirem Alomem popisuje dvě modifikace neuronové sítě (označené jako RU-Net a R2U-Net) založenou na spojení sítě U-Net a rekurentní reziduální konvoluční neuronové sítě. Architektura nazvaná RU-Net využívá, místo klasických, rekurentní konvoluční vrstvy a to v kódující i dekódující části sítě. R2U-Net architektura se liší pouze v reziduálním zapojení, jinak také obsahuje rekurentní konvoluční vrstvy. Využití je demonstrováno na třech různých segmentačních problémech - cévní řečiště v sítnici oka, rakovina kůže a nádory plic. Datová sada pro segmentaci cévního řečiště sítnice obsahovala 20 snímků a trénovací set byl vytvořen pomocí náhodného generování výseků (patches) snímků. U segmentace nádorů kůže resp. plic bylo k dispozici 2000 resp. 534 snímků, které byly v rámci předzpracování podvzorkovány. Pro vytvoření učící sady bylo opět využito augmentačních technik. Úspěšnost segmentace autoři vyhodnotili pomocí více metrik, např. senzitivity (SE), kterou vyčíslili jako podíl správně vyhodnocených a součtu správně a špatně vyhodnocených pixelů. Cévní řečiště sítnice segmentovala síť RU-Net s SE rovným 0,78 a u R2U-Net 0,79. Dále autoři pro segmentaci nádorového onemocnění kůže uvádí výsledky pouze pro R2U-Net s průměrnou hodnotou SE 0,95. Nádory plic síť RU-Net segmentovala se senzitivitou 0,97 a R2U-Net s výsledkem 0,98. Výsledky dokázali, že jimi modifikované architektury mají vyšší úspěšnost ve srovnání s klasickou U-Net a to pro všechny vyzkoušené aplikace.

Další modifikaci populární sítě představili v publikaci [54] autoři Zhou, Siddiquee, Tajbakhsh a Liang jako UNet++. Tuto síť srovnávali s původní architekту-

rou hned v několika segmentačních problémech, kterými byly segmentace: hrudníku v CT snímcích pořízených s nízkou dávkou záření, buněčného jádra v mikroskopických snímcích, játra v CT datech a polypy v kolonoskopickém videu. Architektura UNet++ má mezi enkodérem a dekodérem sérii vnořených konvolučních bloků, jedná se tedy o rozdělení na dvě subsítě, jejichž spojení má přepracované cesty oproti klasické U-Net. Příznakové mapy jsou v klasické architektuře posílány z enkódovací části přímo do dekodovací, u UNet++ ještě prochází hustě propletenou sítí konvolučních bloků, kde počet konvolučních vrstev závisí na úrovni v pyramidovém uspořádání sítě. Autoři ve své implementaci testovali vliv zařazení techniky deep supervision (DS), díky které můžou buď použít přesný režim, kdy se výstupní hodnota získá průměrováním výstupů jednotlivých větví, nebo mohou zvolit rychlý režim, kdy se bere v potaz pouze jedna výstupní hodnota, čímž se sníží výpočetní náročnost a rychlost. V uvedených výsledcích je u všech experimentů patrný lepší výsledek Unet++ oproti klasické architektuře. Největší rozdíl byl zaznamenán u segmentace jater, kdy procentuální rozdíl IoU metriky mezi klasickou a modifikovanou alternativou byl 6,3%. Nejvyšší průměrné hodnoty IoU ze všech experimentů bylo dosaženo u segmentace buněčných jader s výsledkem 92,6%.

Využití 3D varianty sítě U-Net (3D U-Net) byla v literatuře popsána například pro segmentaci mozkových arterií na angiografických CT (CTA) a MR (MRA) snímcích v článku [8]. Autoři zde natrénovali model bez předchozí anotace dat. Učení probíhalo ve dvou fázích, výsledkem první byly na snímcích z angiografické MR označené vaskularizace, dále muselo být provedeno lícování s CT snímky pomocí rigidních transformací. Po registraci snímků mohla být zmenšena oblast zájmu - na základě anatomických znalostí byly zkoumány velikosti propojených oblastí a hodnota HU, dále byly odečteny kostní struktury. Data pro trénování byla generována z takto předzpracovaných oblastí tak, že se náhodně vybíraly 3D výseky, přičemž jejich velikost u vstupních obrazů byla 64x64x64 a u výstupních predikovaných výseků 24x24x24. Vyhodnocení autoři prováděli výpočtem překrytí objemu vaskularizace na CTA i MRA snímcích, dále srovnávali relativní rozdíl objemů a další parametry. Výsledná segmentace na CTA snímcích měla obecně větší objem, zahrnovala i segmentaci některých menších nevýrazných cév, které byly v první fázi opomenuty. Tímto přístupem došlo celkově k zpřesnění výsledků.

4 Datová sada

Data využitá pro účely vypracování této práce byla zapůjčena firmou TESCOAN Medical s.r.o. a obsahovala celkem 200 pacientů. U všech se jedná o CT snímky lebky a většina případů má na klenbě lebeční otvor po chirurgickém zákroku. Nejčastěji jsou to kontrolní snímky po provedené kraniektomii sloužící k plánování kranioplastiky, ale v datové sadě jsou také zahrnuti pacienti s již provedenou kranioplastikou, kdy data byla získána za účelem plánování reoperace či výměny implantátu. Data byla poskytnuta ve formátu *.npy* (jedná se o formát pro ukládání NumPy polí).

4.1 Akvizice dat

Pacientská data byla nasnímaná v několika nemocničních pracovištích pomocí CT systémů s různými akvizičními parametry. Tloušťka řezů nebyla u všech dat stejná, pohybovala se od 0,3 mm po 1,2 mm, přičemž nejvíce zastoupená byla hodnota 0,5 mm.

Vzhledem k účelu, za kterým byla data pořízena, byla v některých případech nasnímaná pouze mozková část lebky, od horního okraje očnice směrem nahoru. Počty získaných řezů se u jednotlivých pacientů lišily, největší dataset jich obsahoval 852, průměrně se ale jednalo o velikost kolem 250 snímků.

4.2 Anotace dat


Všechny pixely obrazu byly rozděleny do dvou kategorií: kost a pozadí. Anotace byly vždy vytvořeny nebo schváleny odborníky.

Do třídy kost byly zařazeny i pixely některých dutin, ukázka jednoho 2D axiálního řezu s výskytem dutin je na obrázku 4.1, kde vlevo je originální snímek a vpravo je modrou barvou vyznačená anotace. V části s anotací je ještě odlišena kost a dutiny, kdy tmavší odstín modré barvy zvýraznil všechny dutiny zahrnuté do anotace.

K přiřazování dutin do stejné kategorie jako kost bylo přistoupeno z čistě praktických důvodů umožňujících snazší výrobu implantátu, oblast zájmu tímto postupem nebyla nijak ovlivněna.

4.3 Předzpracování dat

Nejprve byli vyřazeni pacienti po kranioplastice, protože by mohli mít negativní vliv na učení sítí. Tyto případy (pravděpodobně se jedná o kontrolní snímky) totiž v originálních datech již nemají v klenbě lebeční otvor, ale v anotacích ano.



Obr. 4.1: Ukázka jednoho axiálního 2D řezu, vlevo originální obraz, vpravo fúze originálního snímku a anotované masky. Modrá barva označuje části zařazené do kategorie kost, pomocí tmavšího odstínu této barvy byly zvýrazněny dutiny.

Nutným a nejdůležitějším krokem předzpracování dat byla jejich normalizace. Housfieldovy jednotky (HU) byly převedeny na rozsah 0 až 1 podle rovnice 4.1.

$$f_{i,k} = \frac{f_{i,k} - f_{min}}{f_{max} - f_{min}}, \quad (4.1)$$

kde $f_{i,k}$ je jasová hodnota obrazu na pozici s indexy i a k , f_{min} resp. f_{max} je minimální resp. maximální jasová hodnota obrazu. Aby byly všechny obrazy normovány stejně byly f_{min} a f_{max} nastaveny na 0 a 4000. [19]

Následně bylo provedeno zmenšení obrazu (axiálního řezu) z rozměru 512×512 na 128×128 , díky tomu se významným způsobem snížila paměťová náročnost a umožnila plánování rozsáhlejších experimentů.

5 Návrh a implementace

Pro řešení segmentace lebečních kostí v CT snímcích byla využita architektura sítě U-Net - její 2D i 3D verze. Implementace obou přístupů byla provedena v jazyce Python pomocí knihovny Tensorflow 2.0, ve které je již integrovaná knihovna pro hluboké učení - Keras. V následujících podkapitolách jsou popsány architektury obou variant sítí a metriky hodnocení jejich úspěšnosti.

5.1 Architektura 2D sítě

Implementace 2D varianty konvoluční neuronové sítě U-Net byla inspirována v [48].

Vstupní vrstva přijímala normované a zmenšené obrazy o velikosti $128 \times 128 \times 3$. Sestupná část (enkodér) U-Net architektury byla tvořena sítí MobileNetV2 předtrénovanou na datasetu ImageNet. Původní vstupní rozměr obrazu se postupně zmenšuje přes 64×64 vždy na polovinu až po 4×4 , prostorová velikost se v sestupné části tedy zmenšuje, hloubka se naopak zvětšuje.

Základní blok typický pro MobilNetV2 je podle [43] složen z větve identity a části s konvolucí 1×1 následovanou hloubkovou (*depthwise*) konvolucí s velikostí jádra 3×3 - za těmito oběma vrstvami je modifikovaná ReLU (*ReLU-6*). Před sčítáním větví je zařazena ještě jedna konvoluce 1×1 tentokrát následovaná lineární aktivací vrstvou. Při každém přechodu do nižší vrstvy architektury U-Net se po zmenšení šířky a výšky obrazu zařadila ještě vrstva s batch normalizací.

Jak bylo popsáno již v 2.3.3 sestupná a vzestupná část sítě je propojená spoji, díky kterým se v vzestupné části mohou využít informace i z méně hlubokých vrstev.

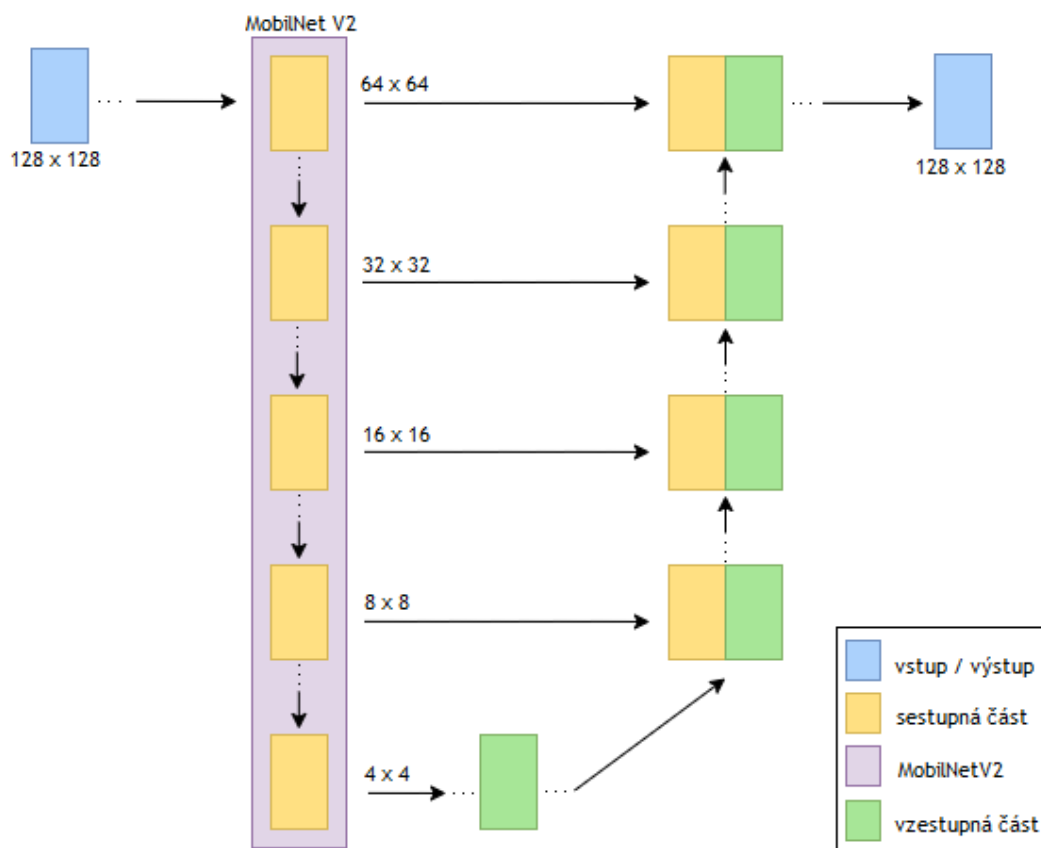
Dekódující část tvoří bloky transponované konvoluce zajišťující postupnou změnu velikosti obrazu z 4×4 na původních 128×128 . Transponovaná konvoluce je na každé úrovni architektury následovaná vždy vrstvou s batch normalizací a s ReLU aktivací.

Jako aktivací funkce poslední vrstvy byla zvolena sigmoida, jejíž zápis (podle [28]) je v následující rovnici:

$$f(\alpha) = \frac{1}{1 + e^{-x}}, \quad (5.1)$$

kde $f(\alpha)$ je aktivací funkce, x vstupní hodnoty.

Počet výstupů byl nastaven na jeden, který díky prahování klasifikoval vzorky do kategorií kost a pozadí. Hodnota prahu byla určena na 0,5. Schématické vyobrazení 2D architektury je na obrázku 5.1.



Obr. 5.1: Zjednodušené schéma 2D architektury.

5.2 Architektura 3D sítě

Segmentace klenby lebeční na dostupných datech byla provedena také pomocí 3D varianty U-Net, model sítě vycházel z článku [10] a implementace bloků byla inspirována podle [14].

Z důvodu omezení pamětovou kapacitou by nebylo možné načítat celé objemy jednotlivých pacientů, a proto byly síti na vstup dávány menší krychle (*patche*) s velikostí hrany o určitém počtu pixelů.

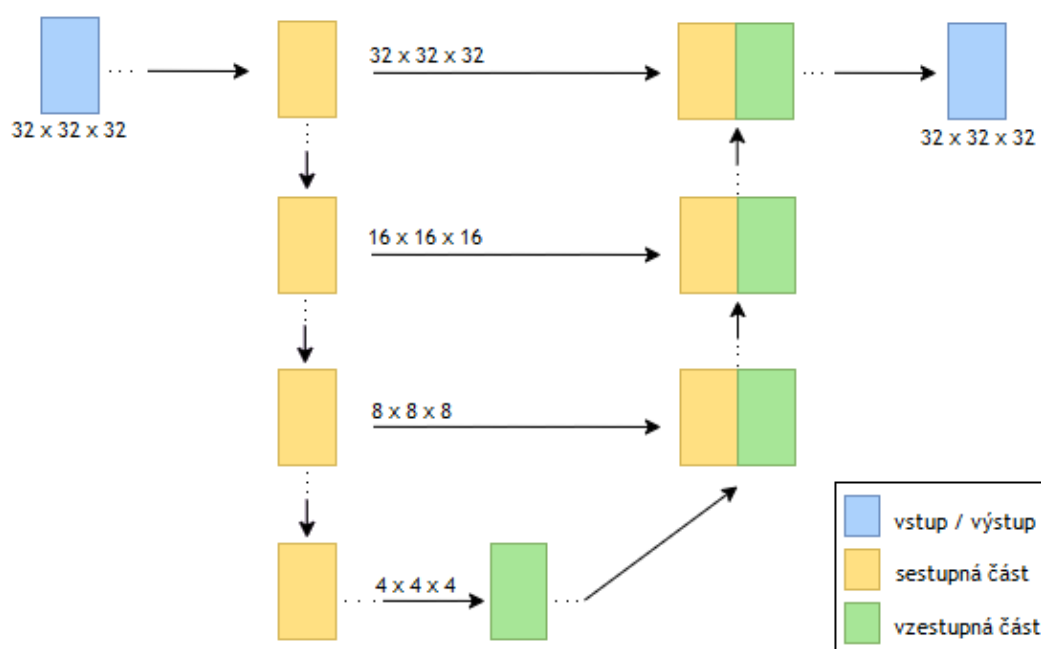
Veškerá data všech pacientů byla po normalizaci a zmenšení na rozměr 128×128 uložena do hierarchického datového formátu HDF5. Takto vytvořená databáze byla snadno přístupná pro datový generátor, který v ní ukázal na konkrétního pacienta, jeho data i anotace byly načteny do paměti a následně z něj byly vytvořeny malé krychle, které generátor postupně posílal na vstup síti.

Sestupná část U-Net architektury byla (stejně jako vzestupná část) tvořena čtyřmi úrovněmi. Každá úroveň byla tvořena dvěma po sobě jdoucími konvolučními bloky. Každý z nich se skládal z 3D konvoluce (s jádrem velikosti $3 \times 3 \times 3$, krokem $1 \times 1 \times 1$), po které byla provedena ReLU aktivace. Při přechodu na nižší úroveň opět

docházelo ke zmenšování prostorového parametru a zvětšování hloubky příznakových map díky 3D max-pooling operaci s velikostí okna $2 \times 2 \times 2$ (například při velikosti vstupního objemu dat $1 \times 32 \times 32 \times 32$ bylo popsány operacemi postupně dosaženo na nejnižší úrovni U-Net architektury rozměru $512 \times 4 \times 4 \times 4$).

Ve vzestupné části byly spoje mezi jednotlivými úrovněmi zajištěny 3D trasponovanou konvolucí s velikostí jádra i krokem velikosti $2 \times 2 \times 2$. Po přechodu na vyšší úroveň bylo provedeno spojení (konkatenace) s příznakovou mapou na konci odpovídající úrovni sestupné části, následované dvěma již popsány konvolučními bloky. V nejvyšší úrovni vzestupné části byla za druhým konvolučním blokem zařazena ještě $1 \times 1 \times 1$ 3D konvoluce a aktivace pomocí sigmoidy (rovnice 5.1). Na základě prahu bylo rozhodnuto o predikci do kategorie kost nebo pozadí.

Zjednodušené schéma popsané 3D architektury je na obrázku 5.2.



Obr. 5.2: Zjednodušené schéma 3D architektury.

5.3 Metriky hodnocení úspěšnosti

Pro zhodnocení úspěšnosti predikce na testovací množině byly využity dvě odlišné metriky - jedna pro celkovou úspěšnost a druhá pro zaměření pouze na oblast lebky.

Přesnost (accuracy, ACC) je podíl správně klasifikovaných pixelů a celkového počtu všech pixelů, většinou se ještě provádí přepočet na procenta. Vztah lze zapsat jako:

$$ACC = \frac{S}{N}, \quad (5.2)$$

kde S je počet správně klasifikovaných pixelů a N je celkové množství pixelů (správně a špatně klasifikovaných dohromady).

Další informace o správnosti výsledků můžeme získat výpočtem Jaccardova indexu jinak označovaného jako průnik nad sjednocením (*Intersection over Union*, IoU). Jeho tvar udává rovnice 5.3 a jedná se o metriku, která přiblíží, jak dobře se podařila segmentace daného objektu. [40, 31]

$$IoU = \frac{TP}{TP + FP + FN}, \quad (5.3)$$

kde TP označuje počet správně klasifikovaných pixelů, FP resp. FN množství falešně pozitivních resp. falešně negativních přiřazení ke třídám.

V datech s nerovnoměrným zastoupením kategorií má IoU oproti ACC vyšší výpovědní hodnotu, protože počítá pouze s pixely, které byly nebo měly být označeny jako kategorie kost.

5.4 Finální úpravy predikovaných snímků

V případě nutnosti odstranění falešně pozitivních pixelů pro dosažení vyšší úspěšnosti klasifikace byly do návrhu zařazeny dvě finální (postprocessing) úpravy a jejich kombinace.

První z navržených finálních úprav sloužící k odstranění případných malých falešně pozitivních shluků s využitím metody aktivních kontur, která by byla aplikována na predikovaný binární obraz - výstup sítě. Implementace aktivních kontur pocházela z knihovny OpenCV, která slouží pro analýzu obrazů. Nejprve byly kontury nalezeny, následně byl zjištěn obsah jejich vnitřních oblastí. Z obrazu jsou poté odstraněny ty oblasti, které jsou menší než experimentálně stanovený práh.

Vylepšení drobných nedokonalostí (osamocených FP pixelů) by mohlo být dosaženo také 2D mediánovým filtrem, velikost okna procházejícího obrazem musí být také stanovena experimentálně.

6 Experimenty a výsledky

V následující kapitole je popsán způsob vybírání dat pro trénování sítí, jejichž architektury byly popsány v 5.1 a 5.2, dále nastavení implementovaných sítí pro učení, způsob testování a v poslední části také jejich srovnání.

6.1 2D U-Net

2D varianta sítě U-Net byla natrénována za pomoci axiálních řezů CT daty pacienta. Nejprve bylo nutné nalézt optimální rozdělení do datových množin, vybrat vhodnou ztrátovou funkci a nastavení hyperparametrů.

6.1.1 Datová množina pro 2D síť

S ohledem na výpočetní náročnost a možnosti nebyla využita celá datová sada. Z dostupných dat bylo náhodně vybráno 67 pacientů, 50 bylo vybráno pro trénování, 4 byly využity pro validaci a zbylých 13 pro testování úspěšnosti modelu. U zvolených pacientů byl proveden ještě náhodný výběr 120 řezů, aby všechny naučené modely mohly být na základě stejného objemu dat pro učení i testování srovnány. Velikosti jednotlivých datových množin v počtech řezů jsou přehledně uvedeny v tabulce 6.1.

Tab. 6.1: Tabulka velikostí datových množin pro učení modelu 2D U-Net.


datová množina	počet řezů
trénovací	6000
validační	480
testovací	1560

6.1.2 Výběr ztrátové funkce

Důležitým krokem při sestavování finální podoby sítě (před jejím testováním) byl experimentální výběr ztrátové (*loss*) funkce, hodnocení jednotlivých variant bylo prováděno po deseti epochách. Pro zjištění nejvhodnější ztrátové funkce mohla být, pro tento případ, také oproti popisu v 6.1.1 zmenšena datová množina a trénování modelů probíhalo pouze na 30 trénovacích pacientech a 5 stejných testovacích pacientech.

Výsledek predikce s použitím původního nastavení podle [48] (s funkcí *cross entropy*) je na obrázku 6.1, průměrná hodnota IoU u 5 testovacích pacientů dosahovala pouze 1,4 %, síť nezařadila do kategorie kost buď žádné pixely nebo pouze malý

počet. Vzhledem k velkému nepoměru počtu pixelů pozadí a kosti v každém řezu byla ale její průměrná ACC i přes to vysoká a rovnala se 93,8 %.




Obr. 6.1: Příklad klasifikace s využitím cross entropy ztrátové funkce. Vlevo je požadovaný výstup a vpravo skutečná predikce sítě.

Další postup byl na základě předchozího výsledku IoU a ACC zaměřen na výběr ztrátové funkce vhodné pro nevyrovnané zastoupení tříd. Velký nepoměr v zastoupení je patrný právě z velmi nízké hodnoty IoU a vysoké ACC. Další model byl naučen tentokrát za pomoci funkce *dice loss* (Diceova ztrátová funkce), která je odvozena z Diceova koeficientu podobnosti a její vztah, vycházející z [47], je v následující rovnici.

$$DL = 1 - \frac{(2 \cdot y_t \cdot y_p) + s}{(y_t + y_p) + s}, \quad (6.1)$$

kde DL je výstup Diceovy ztrátové funkce, s je konstanta (nastavená na 1), y_t je skutečný výstup a y_p predikovaný výstup.

Metrika IoU dosáhla průměrné úspěšnosti 4,7 % a ACC 93,9 %, příklad segmentace jednoho z testovaných řezů je na obrázku 6.2.




Obr. 6.2: Příklad klasifikace pixelů s využitím Diceovy ztrátové funkce. Vlevo je požadovaný výstup a vpravo skutečná predikce sítě.

Nakonec se pro další experimenty jevil jako nejvhodnější výběr *focal loss* (fokální ztrátové) funkce, podle [30] zapsané do rovnice jako:

$$FL = -(\alpha \cdot (1 - y_p)^\gamma \cdot y_t \cdot \log(y_p) + (1 - \alpha) \cdot y_p^\gamma \cdot (1 - y_t) \cdot \log(1 - y_p)), \quad (6.2)$$

kde FL je výstup fokální ztrátové funkce, y_t je skutečný výstup a y_p predikovaný výstup. Protože tato ztrátová funkce vychází z binární cross entropie a zahrnuje ještě dva faktory: balanční faktor α a zaměřující faktor γ snižující vliv častější třídy a zvýhodňující tu, která je méně zastoupená. Ukázka výstupu segmentace jednoho řezu je na obrázku 6.3. IoU dosáhlo procentuální hodnoty 15,5 % a ACC 94,6 %.

Všechny modely naučené za účelem srovnání vlivu výběru ztrátové funkce měli při trénování zamrazenou enkódující (sestupnou) část s předučanou sítí MobilNetV2. Pokud byla tato část odmražena a síť se učila celá došlo u modelu s fokální ztrátovou funkcí k dalšímu zlepšení průměrné ACC na 94,8 % a IoU na 26,4 %.



Obr. 6.3: Ukázka klasifikace s využitím fokální ztrátové funkce. Vlevo je požadovaný výstup a vpravo skutečná predikce sítě.

6.1.3 Trénování 2D sítí

Na základě předchozího zjištění optimálních nastavení bylo naučeno 20 sítí po 50 epochách pro 20 různých (náhodně vygenerovaných) datových sad.

Vzhledem k velkému počtu dostupných dat bylo místo křížové validace aplikováno schéma náhodné validace. Ze všech dat bylo vybráno náhodně 67 pacientů, došlo k rozdělení popsaném v části 6.1.1, po natrénování na 6000 řezech následovalo otestování odložených 1560 řezů. Celý cyklus byl zopakován 20×.

Kompletní tabulka s výsledky je kvůli přehlednosti v příloze A, část z nich však byla pro představu uvedena i do tabulky 6.2. Procentuální hodnoty správnosti klasifikace jsou v obou zmíněných tabulkách uvedeny vždy průměrně pro všechny řezy všech pacientů. Průměrná přesnost (ACC) dvaceti sítí byla 99,1 %, směrodatná odchylka vyhodnocení touto metrikou se rovnala přibližně 0,2 %. Jaccardův index (IoU) dosáhl průměrně 89,4 % se směrodatnou odchylkou 1,6 %. Nejhorší výsledek

byl zaznamenán u sítě označené číslem 8 s ACC rovnající se 98,7 % a IoU dosahující 85,7 %, naopak nejlépe kosti klenby lebeční klasifikovala síť číslo 6, jejíž průměrné ACC bylo 99,4 % a IoU 91,7 %. Ve všech případech byl u metriky IoU zaznamenán velmi velký vliv na nárůst procentuální hodnoty s navýšením počtu epoch, finální hodnota 50 byla určena experimentálně, přidávání dalších epoch už ve většině případů mělo negativní vliv.


U některých sítí se hodnoty ACC a IoU výrazněji liší, což je způsobeno nepoměrem v zastoupení tříd. Snímky obsahují velké množství pixelů pozadí, takže chyby v klasifikaci pixelů lebky se při pohledu na přesnost (ACC), zdají málo časté. Oproti tomu metrika IoU byla zaměřena na pixely kategorie kost. Při jejím výpočtu byly zahrnuty pixely: správně klasifikované a ty oproti anotovaným datům označené navíc či chybně opomenuty. Pomocí IoU byla tedy získána jasnější představa o úspěšnosti klasifikace pixelů kostí lebky bez ohledu na mnohonásobně větší množství pixelů pozadí.

Tab. 6.2: Tabulka výsledků pěti testovaných sítí pro metriku přesnost (ACC) a Jaccardův index (IoU) uvedených v procentech. Celá tabulka je v příloze A.1.

číslo sítě	ACC [%]	IoU [%]
5	99,35	91,43
10	99,20	90,22
15	99,34	90,63
20	99,28	91,31


Obecně dosahovaly lepších výsledků testovací data pacientů s nasnímanou pouze horní částí klenby lebeční (od nadočnicových oblouků výš). Jaccardův index pro klasifikaci těchto oblastí nikdy neklesl pod 90 %. Příklad je na obrázku 6.4, kde je vyobrazen originální axiální řez, anotace, predikce a porovnání anotace s predikcí. Na první pohled není zřejmý žádný rozdíl mezi anotací a predikcí. Při objektivním vyhodnocení tohoto snímku bylo zjištěno, že ACC je 99,8 % a IoU 95,9 %. Celkem v něm bylo nalezeno 24 falešně pozitivních a 9 falešně negativních pixelů. Tyto nesprávně klasifikované pixely jsou zakresleny do porovnání, kvůli jejich malému množství jsou zde viditelné až při bližším pohledu. Pixely, které oproti anotaci chybí (FN) mají zelenou barvu a ty, které naopak přebývají (FP) mají barvu růžovou.

Naopak nejvíce problematické pro predikci byly oblasti s dutinami a se spodinou lebeční. Příklady grafických výstupů klasifikace axiálních řezů s dutinami jsou na obrázcích 6.5 a 6.6 (další ukázky jsou v příloze B). První z uvedených obrázků (6.5) je příkladem dobré predikce, kdy byly téměř přesně vyplněny i dutiny. Výsledek ACC a IoU byl u tohoto axiálního řezu 99,7 % a 96,4 %, bylo u něj detekováno 13 pixelů



Obr. 6.4: Ukázka výstupu 2D sítě s tabulkovým označením 30 zahrnující originální data, anotaci, predikci sítě a srovnání predikce s anotací. Na obrázku porovnání jsou barevně odlišeny pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou.


falešně pozitivních a 43 falešně negativních. Nesrovnalosti byly v tomto případě rozptýleny po celém obvodu objektu, nebyly koncentrovány do větších shluků. Vnitřek dutiny nosní byl vyplněna správně, bez falešně negativních pixelů obvyklých v těchto místech.



Obr. 6.5: Ukázka výstupu 2D sítě s tabulkovým označením 28 zahrnující originální data, anotaci, predikci sítě a srovnání predikce s anotací. Na obrázku porovnání jsou barevně odlišeny pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Nesrovnalosti jsou v tomto případě pouze po obvodu objektu, dutiny je vyplněna zcela správně.

Na druhém z obrázků (6.6) je příklad řezu mimo oblast klenby lebeční, na kterém byly chybně klasifikované oblasti patrnější. Především zelené (falešně negativní) oblasti na horních okrajích dutiny nosní. Tento axiální řez byl predikován sítí s tabulkovým označením 14, úspěšnost predikce byla 98,7 % (ACC) a 91,1 % (IoU).

Vzhledem k tomu, že tvary dutin jednotlivých pacientů nejsou shodné a anotace je zahrnují bez většího podložení své existence v originální datech, má síť při kla-



Obr. 6.6: Ukázka výstupu 2D sítě s tabulkovým označením 14 zahrnující originální data, anotaci, predikci sítě a srovnání predikce s anotací. Na obrázku porovnání jsou barevně odlišeny pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Nesrovnalosti jsou v tomto případě pouze po obvodu objektu, dutina je vyplněna správně.


sifikaci těchto oblastí těžký úkol. Anotovaná data také pochází od více odborníků a nejsou dokonale sjednocené v určování kategorie u některých detailů.

6.1.4 Finální úpravy

Dalšího zlepšení výsledků je možné dosáhnout finálními úpravami (*postprocessing*), vybrané metody byly popsány v části 5.4. Navržený postup je vhodný pro predikce s menším množstvím falešně pozitivních pixelů nebo pro případ, kdy došlo také k chybné predikci kategorie kost u některých částí podložky pod pacientem.

Nejprve byla na predikovaná data aplikována metoda aktivních kontur. Po zanalyzování velikostí oblastí uvnitř vyhledaných kontur byly odstraněny ty, které byly menší než 5 pixelů (tento práh byl opět stanoven experimentálně). Oproti průměrné hodnotě Jaccardova indexu predikce všech natrénovaných sítí se po aplikování této metody zhoršily výsledky průměrně o 0,3 %. Na grafickém výstupu této finální úpravy bylo možné vidět odstranění výše zmíněných negativních jevů, avšak za cenu rozšíření děr v dutinách. Namísto původních osamocených pixelů uvnitř plochy dutiny (nebo případně kosti) se objevily artefakty ve tvaru křížků (kategorie pozadí se ze středové pozice rozšířila i na jeho čtyř-okolí), příklad je na obrázku 6.7.

Na základě zjištění o vytvoření výše uvedených artefaktů byl před metodu aktivních kontur zařazen ještě 2D mediánový filtr. Velikost okna byla určena na 3×3 . Záměrem bylo docílit odstranění nežádoucího vlivu špatně klasifikovaných pixelů, jak mimo lebku, tak v dutinách a to bez vzniku artefaktů. Celkově ale došlo oproti predikci i zde ke zhoršení výsledků, průměr přes všechny natrénované sítě a celá jejich testovací data byl u metriky IoU o 0,8 % horší a vzniklý artefakt se nepovedlo



Obr. 6.7: Ukázka výstupu metody aktivních kontur aplikované na predikovaná data. V červeném rámečku je označená oblast vzniku artefaktu v predikovaném řezu a následně po dokončení finální úpravy.

předřazeným mediánovým filtrem eliminovat v dostatečné míře.

Závažnějším problémem, než přetrvávající zvětšení děr v dutinách, byl fakt, že velká část všech případů obsahovala několik axiálních řezů, kde byla stěna lebečních kostí velice tenká a mediánový filtr strukturu narušil. Příklad přerušení lebeční kosti vlivem použití popsané kombinace finálních úprav je na obrázku 6.8.




Obr. 6.8: Ukázka výstupu kombinace mediánového filtru a aktivních kontur aplikované na predikovaná data. V červeném rámečku je označená oblast, ve které došlo ke ztrátě nemalé části lebeční kosti.

Konečná podoba používaných finálních úprav zahrnovala aktivní kontury (bez předchozí úpravy mediánovým filtrem) opatřené ještě detektorem artefaktů. Algoritmus aktivních kontur nejprve, stejně jako v předchozích případech, na predikovaných datech našel kontury, zjistil velikost oblasti uvnitř jejich hranice, poté oblasti menší než 5 pixelů zapsal do připravené masky, která měla být nakonec od původního obrazu odečtena. Než ale došlo k odstranění vybraných oblastí, prošel masku detektor hledající křížky (5 pixelů uspořádaných do čtyř-okolí) a tyto struktury následně

vymazal.

Takto navrženou finální úpravou byly odstraněny všechny závažné chyby v predikci - tedy pixely podložky pod pacientem i další menší shluky nesprávně klasifikovaných pixelů kolem lebky. Potlačení drobných děr se uvedeným postupem nepodařilo, podstatné ale je, že nedošlo ke zhoršení jejich stavu. Faktem také je, že by dokonalé vyplnění děr v dutinách nemuselo být vždy žádoucí. V anotacích pacientských dat se v některých místech otvory nacházejí a bylo by velice obtížné i okem poznat, které z nich jsou v predikovaných datech žádoucí a které ne.

Objektivní hodnocení pomocí Jaccardova indexu prokázalo zlepšení průměrné hodnoty všech natrénovaných sítí o 0,3 % oproti predikci bez finálních úprav. Výsledek všech metod pro jednotlivé sítě je uveden v tabulce C.1.



Obr. 6.9: Výstup jednotlivých finálních úprav, vždy se jedná o srovnání s anotací. Rozdělení je následovné: (a) predikce, (b) aktivní kontury, (c) mediánový filtr a aktivní kontury (d) aktivní kontury s detektorem. FP pixely jsou růžové a FN zelené.

Ukázka finálních úprav na vybraném axiálním řezu je na obrázku 6.9. Obrázek má opět barevně odděleny TP, TN, FP a FN pixely. Bílá označuje shodné pixely

srovnávaných obrazů pro kategorii kost a černá pro kategorii pozadí. Zelenou jsou znázorněny části, které oproti anotaci schází a růžovou barvou ty, které naopak přebývají. V části (a) je srovnání predikce s anotací, (b) až (d) jsou ukázky výstupů finálních úprav, popořadě to jsou: aktivní kontury, mediánový filtr s aktivními konturami a nakonec aktivní kontury s detektorem. červený rámeček v části (b) označuje místa, kde vznikl křížek. Za povšimnutí také stojí červený rámeček v (c), kde došlo vlivem závěrečné úpravy ke ztrátě části kosti.

6.2 3D U-Net

Oproti 2D verzi, byly 3D sítě trénovány pomocí malých 3D objemů dat nikoliv z axiálních řezů. Při učení bude tedy předávána také prostorová informace. Datová sada musela vzniknout jiným způsobem než v předchozím případě a s tím souvisela také volba parametrů a způsobu provedení jednotlivých částí algoritmu.

Jako nejvhodnější ztrátovou funkci byla v tomto případě vybrána modifikace Diceova koeficientu. Tvar rovnice je již v 6.1, pouze konstanta s byla nyní nastavena na hodnotu 10^{-5} .


6.2.1 Datová množina pro 3D síť

Při vytváření datové množiny pro 3D síť bylo náhodně vybráno 54 pacientů, ti byli poté rozděleni následovně: 40 pro trénovací množinu, 4 pro validační a 10 pro testovací množinu. Informace o rozřazení do jednotlivých datových množin byla předána generátoru, který měl za úkol získat z databáze postupně vždy jednoho z vybraných pacientů a vytvořit z něj malé krychle dat. Z intervalu hodnot odpovídajícího možným počátečním bodům (vrcholům) krychle pro všechny tři dimenze byl náhodně vygenerován počet indexů odpovídající požadovanému množství krychlí vytvořených z jednoho pacienta. Krychle (patch) byla na základě získaných počátečních souřadnic doplněna podle zadané velikosti. Generátor posílal síti dvojice krychlí - s originálními daty a odpovídajícími anotacemi.

6.2.2 Volba přístupu trénování a testování

Objemová krychle dat musí mít vhodnou velikost hrany, aby v ní byly dobře vystihnuty zájmové oblasti a aby data v ní obsažená nesly dostatečnou informaci pro správné naučení sítě. Vzhledem k velikosti snímků pacientů uložených v databázi, by byla teoreticky největší možná hrana krychle 128 pixelů. Velikost hrany se ale v praxi většinou nastavuje menší než je rozměr původního obrazu a to hlavně z důvodu velké výpočetní náročnosti. Testy, hledající nejvhodnější nastavení pro další

experimenty, byly provedeny pro následující tři velikosti datové kostky: $16 \times 16 \times 16$, $32 \times 32 \times 32$ a $64 \times 64 \times 64$. Pro lepší představu o jejich prostorovém rozložení byly tyto velikosti zobrazeny do 2D axiálního řezu na obrázku 6.10. Jako první byla otestována velikost hrany 16, počet voxelů jedné kostky byl 4096. Průměr pěti takto naučených sítí měl výsledné IoU 49,2 %. Sítě natrénované s daty s velikostí hrany 32 (tedy s 32768 voxelů na jednu kostku) měly průměrný výsledek stejné metriky o více než 6 % vyšší. Podle předpokladu by se úspěšnost měla zvýšit i pro hranu velikosti 64 (262144 voxelů v jedné kostce), ale výsledek byl s ohledem na nutnost úpravy některých parametrů učení dokonce mírně horší než předchozí nastavení. U největší velikosti datové kostky musel být snížen počet těchto výseků vybraných z jednoho pacienta na maximálně 2. Také musel být snížen počet trénovacích pacientů a nastaven parametr velikosti mini-batche (dávky či skupinky dat odeslaných sítí) na 1 a síť se tak nedokázala dobře učit. Velký počet parametrů sítě a výpočetní náročnost neumožnila důkladné otestování datové kostky $64 \times 64 \times 64$, která mohla mít dobré výsledky už díky faktu, že u některých pacientů by se do jedné krychle vešla celá lebka nebo její velká část. Následně byly používány už jenom datové kostky $32 \times 32 \times 32$.



Obr. 6.10: Zobrazení vybraných velikostí hrany 3D kostky v originálních datech.


Dále byl porovnáván přístup použití všech kostek, na které lze bez překryvu patientská data rozdělit, a náhodného výběru pouze určitého množství. Náhodné vybírání bylo na základě výsledků zhodnoceno jako robustnější, protože mohly být pro trénování vybrány data od více pacientů. Robustnější mód využití dat byl při srovnání průměru Jaccardova indexu u 5 sítí lepší o téměř 4 %.

Pro výsledné nastavení všech složek sítě byl také experimentálně zjištěn optimální počet epoch. Na obrázku 6.11 je ukázka predikce 3D sítí na axiálním řezu



Obr. 6.11: Predikce provedená 3D sítí po 10 epochách trénování.

po deseti epochách trénování, kdy má výstup sítě všechny linie hodně tenké a také došlo k úplné absenci predikce dutin. Nejlepšího výsledku bylo nejčastěji dosaženo po dvaceti epochách, u dalšího zvyšování už byly patrné tendence přeučení. Příklad průběhu učení popisuje graf na obrázku 6.12.



Obr. 6.12: Ukázka průběhu učení jedné z testovaných 3D sítí.

Další experiment byl zaměřen na testování sítě, opět byly vyzkoušeny dva různé módy. První z nich rozdělil testovacího pacienta na krychle o vybrané velikosti $32 \times 32 \times 32$ bez překryvu, každá z nich bude predikována sítí a dojde k opětovnému sestavení celého objemu. Druhým přístupem bylo testovacími daty procházeno s překryvem, díky tomuto přístupu mohla být získána také představa o jistotě s jakou síť datové krychle predikuje. Síti bylo dáno několikanásobné množství kostek k predikci, po opětovném seskládání na původní pozici byla výsledná kategorie určena jako střední hodnota ze všech návrhů pro dané místo. Bylo otestováno větší množství různě velkých překryvů, avšak žádný z nich nezajistil průměrné zlepšení metriky IoU o více než 2 desetiny procenta. Takto malý rozdíl nebyl natolik zásadní, aby vykompenzoval několikanásobné zpomalení testování.

6.2.3 Trénování 3D sítí

I v případě 3D architektury bylo natrénováno 20 sítí, pro každou z nich se vytvořila odlišná datová sada. Na základě 6.2.2 byly natrénovány na 20 epoch, velikost jedné kostky byla $32 \times 32 \times 32$, u každého náhodně vybraného pacienta jich bylo vygenerováno 30. Tabulka výsledků všech dvaceti sítí s průměrnými hodnotami dvou používaných metrik pro celé příslušné testovací množiny je v příloze D, část výsledků se také nachází v tabulce 6.3.


Tab. 6.3: Tabulka výsledků pěti testovaných sítí pro metriku přesnost (ACC) a Jaccardův index (IoU) uvedených v procentech. Celá tabulka je v příloze D.1.

číslo sítě	ACC [%]	IoU [%]
5	97,72	69,25
10	98,51	79,27
15	97,53	64,85
20	98,17	72,86


Průměr všech dvaceti sítí dosáhl u ACC 97,6 % se směrodatnou odchylkou téměř 0,7 % a u IoU 67,1 % s velmi vysokou odchylkou rovnou 8,1 %. Nejhorší průměrný výsledek predikce vykazovala síť číslo 3, jejíž Jaccardův index byl pouze 46,7 %. Nejlépe natrénovat se podařilo síť označenou v tabulce číslem 10, IoU u ní dosáhlo 79,3 %.

Ještě více než u 2D sítí hrálo ve výsledcích testování roli, zda se jednalo o pacienta s nasnímanou pouze horní částí klenby lebeční nebo zda data obsahovala také dutiny a další obtížnější struktury. Oba případy jsou ukázány na obrázcích 6.13 a 6.14. Tyto ukázky 3D sítě, stejně jako další příklady v příloze E, zobrazují originální axiální řez, jeho anotaci, síť provedenou predikci a srovnání predikce vůči anotaci. V tomto porovnání jsou zeleně vyznačeny pixely, které v kategorii kost u predikovaných dat chybí, růžově naopak ty, které jsou oproti anotaci do této třídy zařazeny navíc. Objektivní zhodnocení axiálního řezu z obrázku 6.13 ukazuje, že 65 pixelů bylo predikováno jako kost chybně (skupina FP pixelů), ale žádný z kategorie kost nebyl označen jako pozadí, Jaccardův index tedy dosáhl 94,5 %, ACC téměř 99,6 %. Predikce axiálního řezu s dutinou nosní z obrázku 6.14 dopadla podstatně hůř, síť dutinu nepredikovala, IoU bylo stanoveno na 65,8 % a ACC na 95,9 %.


Natrénované sítě 3D varianty byly velice dobře schopny predikovat klenbu lebeční na snímcích bez dutin a spodiny lební. Sítě se nezvládly naučit správnou klasifikaci dutin. Byly však zaznamenány pokusy o dokreslení oblasti, například část řezu v červeném rámečku na obrázku 6.15, ale stejně jako v tomto uvedeném příkladu, se na většině z nich jedná o falešně pozitivní pixely.



Obr. 6.13: Ukázka výstupu 3D sítě s tabulkovým označením 23 zahrnující originální data, anotaci, predikci sítě a srovnání predikce s anotací. Na obrázku porovnání jsou barevně odlišeny pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Nesrovnalosti jsou v tomto případě pouze po obvodu objektu.



Obr. 6.14: Ukázka výstupu 3D sítě s tabulkovým označením 23 zahrnující originální data, anotaci, predikci sítě a srovnání predikce s anotací. Na obrázku porovnání jsou barevně odlišeny pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Na první pohled je patrná absence segmentace dutin.



Obr. 6.15: Ukázka výstupu 3D sítě se špatně predikovanými dutinami zahrnující originální řez, anotaci, predikci sítě a srovnání predikce s anotací. Na obrázku porovnání jsou barevně odlišeny pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. V červeném rámečku je označená část, kterou síť považovala za dutinu.

6.3 Srovnání výsledků 2D a 3D sítě

V následující části budou porovnány výsledky 2D a 3D sítí, kdy testování bylo provedeno na stejné testovací množině. Vybraných 10 pacientů bylo otestováno všemi natrénovanými sítěmi 2D i 3D verze bez finálních úprav. Pro každého testovacího pacienta byl srovnán průměr dvaceti sítí jedné varianty architektury a směrodatná odchylka. Výsledky jednotlivých pacientů pro metriku ACC a IoU jsou v příloze F, celkový výsledek je uveden v tabulce 6.4.

Tab. 6.4: Tabulka srovnání výsledků 2D a 3D sítí (jejich průměru a směrodatné odchylky) pro metriku ACC a IoU v procentech. Uvedené hodnoty jsou průměr pro 10 srovnávaných pacientů.

metrika	průměr [%]		sm. odchyl. [%]	
	2D	3D	2D	3D
ACC [%]	99,08	98,01	0,13	0,30
IoU [%]	89,33	70,32	1,44	5,36


Ve všech případech dopadly lépe výsledky 2D verze. Největší rozdíl průměru IoU dvaceti sítí byl zaznamenán mezi variantami architektury u pacienta v tabulce označeného číslem 10, jednalo se o 30,4 %. Dalšími velmi odlišnými výsledky disponovali pacienti 3 a 8 (s rozdílem kolem 27 %), ve všech třech případech se jednalo o pacienty obsahující dutiny. Naopak nejmenší rozdíl mezi průměrným výsledkem 20 sítí 2D a 3D verze byl u pacienta s číslem 5 s procentuální hodnotou 5,5 %, druhým v pořadí byl potom pacient s číslem 9 s 8,3 %, tito dva pacienti zahrnovali snímky pouze horní části klenby lebeční.

Při pohledu na největší směrodatnou odchylku v tabulce metriky IoU a tedy největší nesoulad mezi dvaceti sítěmi v klasifikaci byla u predikce pacienta 3, pro 2D síť se směrodatná odchylka rovnala téměř 3,7 % a u 3D sítí 11,9 %. Nejvíce podobné procentuální odchylky IoU vykazovaly 2D síť u pacienta 1 (0,6 %) a u 3D varianty u pacienta 8 (3,9 %).

Následně byly porovnány predikce 2D a 3D sítí také graficky. Bylo vybráno několik axiálních řezů, pro které byl zobrazen obraz originálních dat, anotace a poté obrazy s vyznačenými rozdíly predikce oproti anotaci u výstupu z 2D i 3D sítě. Pro obě varianty predikovaly toto srovnání nejlépe natrénované sítě. Rozdíly mezi anotací a predikcí byly opět zvýrazněny barevně - růžová pro pixely zařazené do kategorie kost nesprávně, zelená pro pixely, které do třídy kost měly být označeny.

Na obrázku 6.16 je příklad z oblasti klenby lebeční. Predikce 2D sítí dosáhla ACC 99,8 % a IoU 97,6 %, celkově měla 17 pixelů falešně pozitivních a 13 falešně negativních. Horší výsledky byly získány predikcí 3D sítí s ACC 98,8 % a IoU 86,3 %,

žádné pixely nebyly falešně negativní, ale falešně pozitivních bylo nalezeno 191, ty byly rozprostřené z vnější i vnitřní strany lebečních kostí po celém obvodu a způsobily zvýšení tloušťky stěny.



Obr. 6.16: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,8 %, IoU 97,6 %. Srovnání predikce 3D sítě oproti anotaci: ACC 98,8 %, IoU 86,3 %.

Obrázek 6.17 ukazuje, jak odlišná je schopnost predikce u axiálních snímků z oblasti spodiny lebeční s nutností vyplnění dutin. U srovnání predikce 2D sítě s anotací jsou zřetelné dva větší falešně pozitivní výběžky po stranách lebky, dále je zde (ve shluku falešně negativních pixelů) viditelně špatné ohraničení doplněné dutiny. Přesto bylo na tomto řezu vyhodnoceno ACC na 98,65 % a IoU na 86,67 %, FP pixelů bylo 133 a FN 89. Větší problém měla ale při predikci tohoto řezu opět 3D síť. Na srovnání jejího výstupu s anotací je, kromě falešně pozitivních výběžků po stranách lebky (jako u 2D varianty), také velmi výrazná oblast podložky pod pacientem zahrnutá do predikce, nezdařila se ani klasifikace dutin, které byly opět označeny jako pozadí. Metrika ACC resp. IoU se rovnala 94,6 % resp. 49,5 % s 236 falešně pozitivními pixely a 657 falešně negativními.


6.3.1 3D vizualizace výsledků

Pro subjektivní zhodnocení výsledků byl také vytvořen 3D model pomocí softwaru 3D Slicer. Ukázka vizualizace jednoho pacienta je na obrázku 6.18. 3D model predikce 2D sítě se oproti anotaci v oblasti klenby lebeční liší pouze v detailech, největší rozdíly jsou patrné na nespojitosti v očním důlku a v oblasti nosu. Stejně oblasti (a ještě ve větší míře) predikovala rozdílně oproti anotaci také 3D síť, kromě toho jsou ale také znatelné nedostatky v hladkosti povrchu klenby lebeční. Jedná se především o horní část temene hlavy, kde je výrazný schodovitý přechod. Dochází k tomu proto, že nejvýše položené axiální řezy temene hlavy jsou predikovány správně a od určitého



Obr. 6.17: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 98,7 %, IoU 86,7 %. Srovnání predikce 3D sítě oproti anotaci: ACC 94,6 %, IoU 49,5 %.

bodů síť začne stěny ztlušťovat. U predikce 2D i 3D sítě došlo v tomto konkrétním případě také k nesprávné klasifikaci pixelů v oblasti napojení na krční obratel.




Obr. 6.18: 3D vizualizace anotace, predikce 2D a 3D sítě.

6.3.2 Analýza segmentace v oblastech po chirurgickém zákroku

Na stejných deseti pacientech vybraných pro srovnání výsledků 2D a 3D sítí byla také provedena analýza správnosti segmentace v místech po chirurgickém zákroku (na okrajích děr v lebeční kosti). Pro plánování kranioplastiky je právě tato oblast nejdůležitější, využití predikovaných dat při procesu výroby implantátu je podmíněno vysokou přesností.

Všechny předchozí výsledky vyjadřují celkovou úspěšnost segmentace vzhledem k odborně připraveným anotacím. Proto byly pro vybraných 10 pacientů vytvořeny masky, do kterých byla zanesena poloha okrajů po chirurgickém zákroku a jejího nejbližšího okolí (obrázek 6.19). Tyto informace zjištěné pro každý řez s otvorem v klenbě lebeční sloužily k výpočtu metriky IoU pouze v místě zájmu.



Obr. 6.19: Příklad výběru oblastí pro analýzu oblastí po chirurgickém zákroku. V oblasti označené červeným rámečkem byla určena úspěšnost klasifikace metrikou IoU. Ve zvětšeném náhledu okrajů oblasti po zákroku jsou barevně vyznačené pixely, které nekorespondují s anotací, vyskytují se zde jak FP (růžová), tak FN pixely (zelená).

Výsledky jsou v tabulce 6.5, kde průměrný Jaccardův index pro predikce 2D sítí u 10 pacientů byl 98,4 % se směrodatnou odchylkou 1,6 %. Predikce 3D sítí měly opět výsledek horší, nikoliv však tak dramaticky jako při předchozích srovnáních, průměrné IoU dosáhlo téměř 97 % se směrodatnou odchylkou 3,1 %.

6.3.3 Využití výsledků při plánování kranioplastiky

Stejně jako v ostatních odvětvích medicíny využívajících CNN není možné na výstup sítí zcela spoléhat a standardně se jedná pouze o podpůrný prostředek odborníků.

Tab. 6.5: Tabulka srovnání výsledků 2D a 3D sítí (jejich průměru a směrodatné odchylky) pro metriku IoU v oblasti po chirurgickém zákroku. Uvedené hodnoty jsou průměr pro 10 srovnávaných pacientů uvedený v procentech.

metrika	průměr [%]		sm. odchyl. [%]	
	2D	3D	2D	3D
IoU [%]	98,40	96,95	1,64	3,05

Jak už bylo zmíněno, vysoká přesnost je vyžadována především v oblasti po chirurgickém zákroku, aby implantát navržený na základě patientských dat při samotném výkonu kranioplastiky dobře seděl. Pro plánování kranioplastiky by tedy teoreticky mohly být využity predikce jak 2D, tak i 3D sítí, ale u 3D sítě by v oblasti kolem chirurgického zákroku bylo více dodatečných manuálních úprav.

Schopnosti segmentace dutin 2D sítěmi je další výhodnou vlastností, díky které dojde oproti výstupům z 3D sítí ke značné eliminaci dodatečných manuálních úprav nebo aplikaci vyplňovacích metod.

Závěr

Tato práce se zabývala možnostmi využití konvolučních neuronových sítí pro segmentaci klenby lebeční v CT snímcích pacientů po kraniektomii, jejich implementací a vyhodnocením úspěšnosti predikce. Pro realizaci řešení byla vybrána architektura U-Net, přesněji její 2D i 3D verze.

Variantu 2D architektury měla v sestupné části umístěnu síť MobilNetV2. Trénovací sadu tvořily snímky pocházející od 50 pacientů (od každého bylo ještě náhodně vybráno 120 řezů), validace probíhala na čtyřech pacientech a pro testování bylo vybráno 13 pacientů. Nejprve bylo nutné zvolit chybovou funkci vhodnou pro data s nerovnoměrně zastoupenými kategoriemi. Nejlepších výsledků bylo u této architektury dosaženo s fokální chybovou funkcí. Dále bylo ověřeno, že trénování enkodující části s MobilNetV2 zajistí vyšší úspěšnost klasifikace. Testování 2D architektury bylo provedeno naučením dvaceti sítí vždy s odlišnou datovou sadou, ale o stejné velikosti. Průměrná přesnost naučených sítí po dosažení 50 epoch byla 99,1 % se směrodatnou odchylkou 0,2 %, kvůli velké nevyrovnanosti zastoupení tříd byla ale sledována především průměrná hodnota IoU odpovídající téměř 89,4 % se směrodatnou odchylkou 1,6 %. Následně byly provedeny finální úpravy, které odstranily některé falešně pozitivní shluky, hodnota IoU se díky nim zvýšila na 89,6 %. Nedošlo tedy k významně velkému zlepšení úspěšnosti, ale při posouzení grafických výstupů pomohly odstranit zásadní chyby v podobě nesprávné predikce pixelů podložky pod pacientem.

Druhým způsobem řešení bylo využití 3D architektury sítě U-Net, která na rozdíl od první varianty nevyužívala axiální řezy, ale 3D datové krychle. Datová množina zahrnovala 40 pacientů trénovacích, 4 validační a 10 testovacích. Opět se jednalo o náhodný výběr. Tento způsob implementace vyžadoval výběr optimálního vytváření krychlí z vybraných dat i jejich velikost, dále například způsob zpětného sestavení predikovaných dat do celého objemu. Kvůli omezení technickými možnostmi bylo nakonec natrénováno 20 sítí po 20 epochách, s velikostí vstupních datových krychlí $32 \times 32 \times 32$, kdy od každého trénovacího pacienta jich bylo náhodně vygenerováno 30. Přesnost výstupů 3D architektury byla 97,6 % se směrodatnou odchylkou 0,7 %, metrika IoU byla vyčíslena na 67,1 % se směrodatnou odchylkou 8,1 %.

Pro srovnání 2D a 3D architektury byla vytvořena další testovací množina zahrnující 10 pacientů, která byla otestována všemi naučenými sítěmi. U všech z vybraných pacientů dosáhla vyšší úspěšnosti 2D síť. Při grafickém porovnání výsledků je patrné, že 3D síť velice špatně predikují oblasti dutin a také často predikují širší stěny plochých kostí lebky.

Protože dutiny jsou do anotací zahrnuty především z praktických důvodů, byly další srovnávací analýzy zaměřeny na oblast po chirurgickém zákroku, která je pro plánování kranioplastiky nejdůležitější. V těchto místech bylo dosaženo srov-

natelného výsledku IoU metriky, pro 2D průměrně 98,4 % a pro 3D 97,0 %. U 3D varianty byla ale téměř dvojnásobná směrodatná odchylka 3,1 % oproti 1,6 % pro 2D architekturu.

Pro využití v praxi se jeví být vhodnější 2D architektura, která dosáhla lepších výsledků v oblasti po chirurgickém zákroku a o dost lépe klasifikovala dutiny. Všechna predikovaná data musí být ještě zkontrolována a je nutné manuálně provést doladění detailů. Závěrečné přípravy před procesem návrhu implantátu by tak u výstupu 2D sítě zabraly méně času, než kolik by ho bylo potřeba u 3D sítě.

Literatura

- [1] AHMADIAN, A.; BAA J, A. A.; GARCIA, M.; aj.: Decompressive craniectomy with massive intractable intraoperative cerebral edema: utilization of silicone sheet for temporary scalp closure: Case report. *Journal of Neurosurgery: Pediatrics*, ročník 10, č. 3, 2012: s. 195–199.
- [2] ALOM, M. Z.; HASAN, M.; YAKOPCIC, C.; aj.: Recurrent residual convolutional neural network based on u-net (R2U-net) for medical image segmentation. *arXiv preprint arXiv:1802.06955*, 2018.
- [3] AYDIN, S.; KUCUKYURUK, B.; ABUZAYED, B.; aj.: Cranioplasty: review of materials and techniques. *Journal of neurosciences in rural practice*, ročník 2, č. 2, 2011: str. 162.
- [4] BEISTER, M.; KOLDITZ, D.; KALENDER, W. A.: Iterative reconstruction methods in X-ray CT. *Physica medica*, ročník 28, č. 2, 2012: s. 94–108.
- [5] BISHOP, C. M.: *Pattern recognition and machine learning*. Springer Science+Business Media, 2006, ISBN 0387310738.
- [6] BOTTOU, L.: Large-scale machine learning with stochastic gradient descent. In *Proceedings of COMPSTAT'2010*, Springer, 2010, s. 177–186.
- [7] BUSHBERG, J.; SEIBERT, J.; LEIDHOLDT, E.; aj.: *The Essential Physics of Medical Imaging*. Wolters Kluwer Health, 2011, ISBN 9781451153941.
URL <https://books.google.cz/books?id=RKcTgTqeniwC>
- [8] CHEN, X.; LU, Y.; BAI, J.; aj.: Train a 3D U-Net to segment cranial vasculature in CTA volume without manual annotation. In *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, IEEE, 2018, s. 559–563.
- [9] CHOLLET, F.: *Deep Learning with Python*. Manning Publications Co., první vydání, 2018, ISBN 1617294438, 9781617294433.
- [10] ÇIÇEK, Ö.; ABDULKADIR, A.; LIENKAMP, S. S.; aj.: 3D U-Net: learning dense volumetric segmentation from sparse annotation. In *International conference on medical image computing and computer-assisted intervention*, Springer, 2016, s. 424–432.
- [11] ČIHÁK, R.; GRIM, M.; FEJFAR, O.; aj.: *Anatomie*. Grada, 2011, ISBN 9788024738178.
URL <https://books.google.cz/books?id=bzZxDwAAQBAJ>

- [12] DE LA PEÑA, A.; DE LA PEÑA-BRAMBILA, J.; PÉREZ-DE LA TORRE, J.; aj.: Low-cost customized cranioplasty using a 3D digital printing model: a case report. *3D printing in medicine*, ročník 4, č. 1, 2018: str. 4.
- [13] DRASTICH, A.: *Tomografické zobrazovací systémy*. Vysoké učení technické v Brně, Fakulta elektrotechniky a informatiky, 2004.
- [14] ELIS, D. G.: 3DUnetCNN. <https://github.com/ellisdg/3DUnetCNN>, 2018.
- [15] GEIST, M.: Soft-max boosting. *Machine Learning*, ročník 100, č. 2, Sep 2015: s. 305–332, ISSN 1573-0565, doi:10.1007/s10994-015-5491-2.
URL <https://doi.org/10.1007/s10994-015-5491-2>
- [16] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A.: *Deep learning*. MIT press, 2016.
- [17] HAMPL, M.; HRABÁLEK, L.; VAVERKA, M.; aj.: Autologní kranioplastika deponovanou kostní ploténkou v podkoží mezogastria. *Rozhl. Chir.*, ročník 96, č. 5, 2017: s. 209–2012.
- [18] Medical animation: Cranioplasty, *High Impact, LLC*. [Online; navštíveno 20.10.2019].
URL <https://highimpact.com/exhibits/cranioplasty>
- [19] HOFMANN, F.; SCHWAIGER, M.; SEMMLER, W.: *Molecular Imaging I*. Springer-Verlag Berlin Heidelberg, 2008.
- [20] HOLIBKOVÁ, A.; LAICHMAN, S.: *Přehled anatomie člověka*. Olomouc: Univerzita Palackého v Olomouci, třetí vydání, 2002, ISBN 8024404958.
- [21] HRABOVSKÝ, D.; JANČÁLEK, R.; ŘÍHA, I.; aj.: Komplikace kranioplastik po dekompresivní kraniektomii. *Cesk Slov Neurol N*, ročník 79/112, č. 1, 2016: s. 77–81.
- [22] JAN, J.: *Medical image processing, reconstruction and restoration: concepts and methods*. CRC Press, 2005.
- [23] JARDINI, A.; LAROSA, M.; MACEDO, M.; aj.: Improvement in Cranioplasty: Advanced Prosthesis Biomanufacturing. *Procedia CIRP*, ročník 49, 12 2016: s. 203–208, doi:10.1016/j.procir.2015.11.017.
- [24] JURÁŇ, V.: *Indikace dekompresivní kraniektomie u neurotraumat*. Dizertační práce, Masarykova univerzita, Lékařská fakulta, 2008.

- [25] JURÁŇ, V.; SMRČKA, M.; SVOBODA, K.; aj.: Indikace dekompresivní kraniektomie u traumat mozku. *Cesk Slov Neurol*, ročník 72/105, č. 5, 2009: s. 439–445.
- [26] KARPATY, A.: *Convolutional Neural Networks for Visual Recognition*. [Online; navštíveno 21.9.2019].
URL <http://cs231n.github.io/>
- [27] KIM, S. H.; LEE, S. J.; LEE, J. W.; aj.: Staged reconstruction of large skull defects with soft tissue infection after craniectomy using free flap and cranioplasty with a custom-made titanium mesh constructed by 3D-CT-guided 3D printing technology: Two case reports. *Medicine*, ročník 98, č. 6, 2019.
- [28] KOZUMPLÍK, J.; PROVAZNÍK, I.: *Umělá inteligence v medicíně*: elektronická skripta. ÚBMI FEKT VUT v Brně, 2007, Brno.
- [29] Patient-specific craniomaxillofacial surgical implants and systems *KLS Martin Group*. [Online; navštíveno 21.10.2019].
URL <https://3dprint.com/170483/lasercusing-surgical-implants/>
- [30] LIN, T.-Y.; GOYAL, P.; GIRSHICK, R.; aj.: Focal loss for dense object detection. In *Proceedings of the IEEE international conference on computer vision*, 2017, s. 2980–2988.
- [31] LONG, J.; SHELHAMER, E.; DARRELL, T.: Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2015, s. 3431–3440.
- [32] MASOPUST, V.; HÄCKEL, M.: Kranioplastika na modelu. *Vojenské zdravotnické listy*, ročník 4, 2008: s. 140–144.
- [33] MINNEMA, J.; VAN EIJNATTEN, M.; KOUW, W.; aj.: CT image segmentation of bone for medical additive manufacturing using a convolutional neural network. *Computers in biology and medicine*, ročník 103, 2018: s. 130–139.
- [34] MORALES-GÓMEZ, J. A.; GARCIA-ESTRADA, E.; LEOS-BORTONI, J. E.; aj.: Cranioplasty with a low-cost customized polymethylmethacrylate implant using a desktop 3D printer. *Journal of neurosurgery*, ročník 130, č. 5, 2018: s. 1721–1727.
- [35] MORK, J.; MRAČEK, J.; ŠTĚPÁNEK, D.; aj.: Dekompresivní výkony u pacientů s akutně vzniklou intrakraniální hypertenzí. *84. SVAZEK*, 2018: str. 89.

- [36] MRÁČEK, J.; CHOC, M.: Osteoplastická dekompresivní kraniotomie -indikace a operační technika. *Rozhl. Chir.*, ročník 89, č. 2, 2010: s. 109–112.
- [37] NAVRÁTIL, L.: Dekompresivní kraniotomie u kraniocerebrálních poranění-hodnocení přežití a jeho kvality po jednom roce od úrazu. *Cesk Slov Neurol N*, ročník 70/103, č. 3, 2007: s. 294–301.
- [38] ONO, H.; SASE, T.; TANAKA, Y.; aj.: Histological assessment of porous custom-made hydroxyapatite implants 6 months and 2.5 years after cranioplasty. *Surgical neurology international*, ročník 8, 2017.
- [39] PIAZZA, M.; GRADY, M. S.: Cranioplasty. *Neurosurgery Clinics*, ročník 28, č. 2, 2017: s. 257–265.
- [40] REAL, R.; VARGAS, J. M.: The probabilistic basis of Jaccard's index of similarity. *Systematic biology*, ročník 45, č. 3, 1996: s. 380–385.
- [41] ROBERTS, A. M.: *Kompletní lidské tělo*. Praha: Knižní klub, vyd. 1. vydání, 2012, ISBN 978-80-242-2958-4.
- [42] RONNEBERGER, O.; FISCHER, P.; BROX, T.: U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention*, Springer, 2015, s. 234–241.
- [43] SANDLER, M.; HOWARD, A.; ZHU, M.; aj.: Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018, s. 4510–4520.
- [44] ŠPANĚL, M.; BERAN, V.: Obrazové segmentační techniky: Přehled existujících metod [online]. 2006.
URL <http://www.fit.vutbr.cz/~spanel/segmentace/>
- [45] SRIVASTAVA, N.; HINTON, G. E.; KRIZHEVSKY, A.; aj.: Dropout: a simple way to prevent neural networks from overfitting. *Journal of machine learning research*, ročník 15, č. 1, 2014: s. 1929–1958.
- [46] Cranial iD:Patient specific implants *Stryker*. [Online; navštíveno 21.10.2019].
URL <https://www.stryker.com/us/en/craniomaxillofacial/products/cranial-id.html>
- [47] SUDRE, C. H.; LI, W.; VERCAUTEREN, T.; aj.: Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In *Deep*

learning in medical image analysis and multimodal learning for clinical decision support, Springer, 2017, s. 240–248.

- [48] TensorFlow: Image segmentation.
URL <https://www.tensorflow.org/tutorials/images/segmentation>
- [49] TRIBUDDHARAT, S.; SATHITKARNMANEE, T.; KITKHUANDEE, A.; aj.: A fatal adverse effect of cefazolin administration: severe brain edema in a patient with multiple meningiomas. *Drug, healthcare and patient safety*, ročník 8, 2016: str. 9.
- [50] WALEK, P.: *Analysis of iteratively reconstructed CT data: novel methods for measuring image quality*. Dizertační práce, Brno University of Technology, Faculty of Electrical Engineering and Communication, Department of Biomedical Engineering, 2017.
- [51] WILLEMINK, M. J.; DE JONG, P. A.; LEINER, T.; aj.: Iterative reconstruction techniques for computed tomography Part 1: technical principles. *European radiology*, ročník 23, č. 6, 2013: s. 1623–1631.
- [52] ZACCARIA, L.; THARAKAN, S. J.; ALTERMATT, S.: Hydroxyapatite ceramic implants for cranioplasty in children: a single-center experience. *Child's nervous system*, ročník 33, č. 2, 2017: s. 343–348.
- [53] ZHANG, J.; TIAN, W.; CHEN, J.; aj.: The Application of Polyetheretherketone (PEEK) Implants in Cranioplasty. *Brain research bulletin*, 2019.
- [54] ZHOU, Z.; SIDDIQUEE, M. M. R.; TAJBAKHSI, N.; aj.: Unet++: A nested u-net architecture for medical image segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, Springer, 2018, s. 3–11.

Seznam příloh

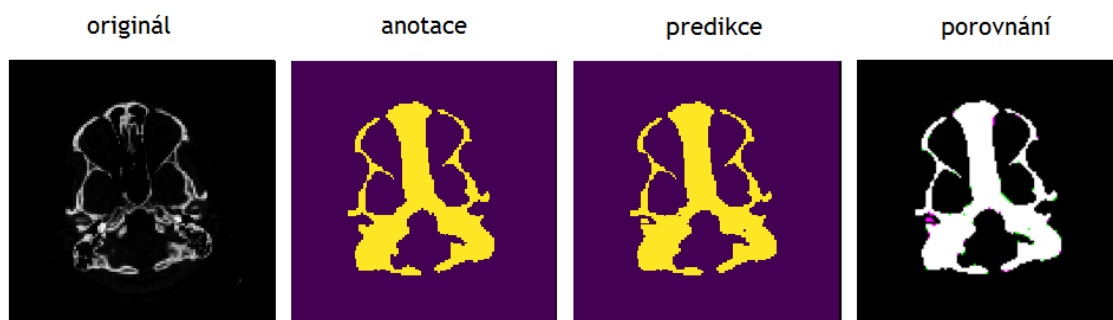
A	Výsledky testování 2D sítě	64
B	Ukázky výstupů testování 2D sítí	65
C	Výsledky 2D sítí po finálních úpravách	69
D	Výsledky 3D sítí	70
E	Ukázky výstupů testování 3D sítí	71
F	Srovnání 2D a 3D sítí	73
G	Grafické srovnání 2D a 3D sítí	75

A Výsledky testování 2D sítě

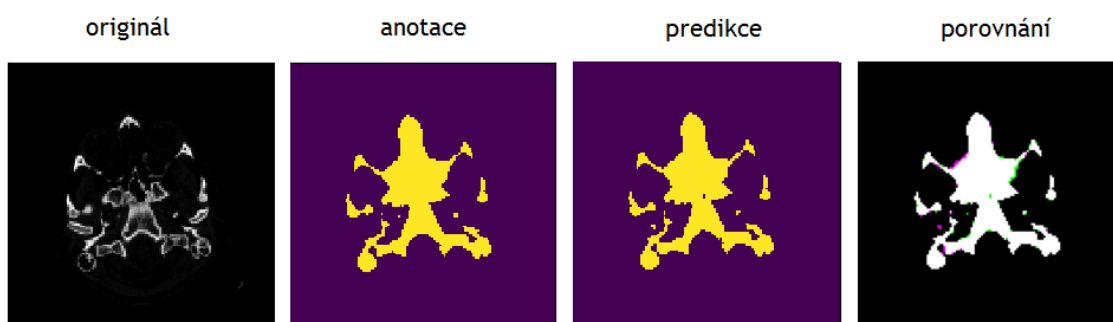
Tab. A.1: Tabulka výsledků pěti testovaných sítí pro metriku přesnost (ACC) a Jac-cardův index (IoU) uvedených v procentech.

číslo sítě	ACC [%]	IoU [%]
1	98,92	87,99
2	99,21	90,35
3	99,32	90,75
4	99,13	89,38
5	99,35	91,43
6	99,35	91,74
7	99,19	90,30
8	98,71	85,68
9	98,93	87,72
10	99,20	90,22
11	99,15	87,27
12	99,10	89,33
13	99,03	87,00
14	99,11	89,32
15	99,34	90,63
16	99,12	90,27
17	99,22	89,64
18	98,96	88,31
19	99,18	88,54
20	99,28	91,31
průměr	99,14	89,36
sm. odchyl.	0,16	1,59

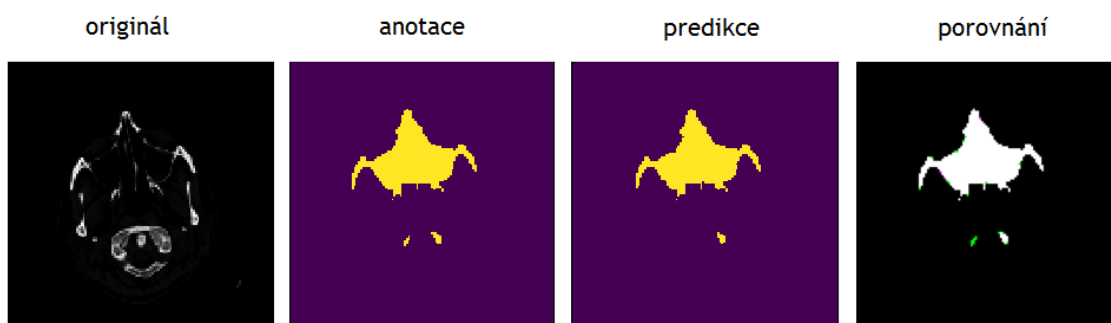
B Ukázky výstupů testování 2D sítí




Obr. B.1: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,7 % a IoU 97 %.




Obr. B.2: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,7 % a IoU 95,7 %.



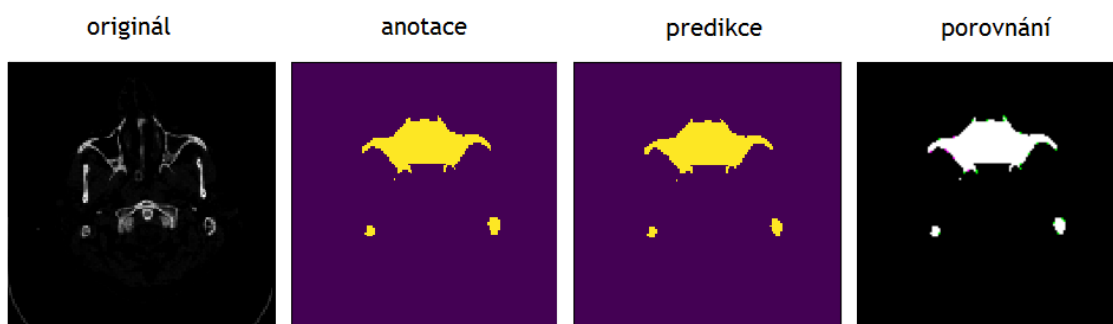
Obr. B.3: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,8 % a IoU 97,5 %.




Obr. B.4: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,6 % a IoU 87,9 %.




Obr. B.5: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,2 % a IoU 87,1 %.



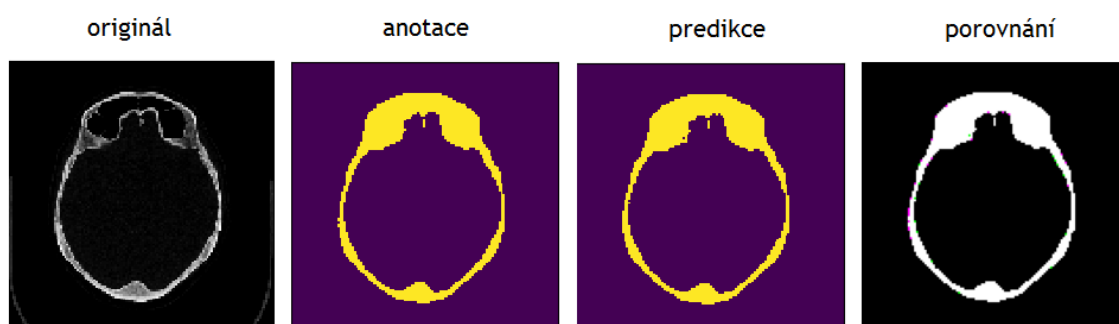
Obr. B.6: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,8 % a IoU 96,9 %.




Obr. B.7: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 97 % a IoU 83,2 %.



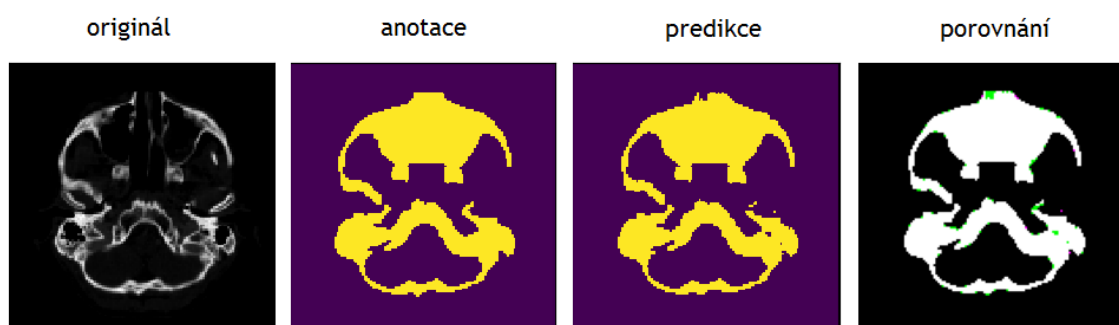
Obr. B.8: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 97,3 % a IoU 78,2 %.



Obr. B.9: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,8 % a IoU 97,8 %.



Obr. B.10: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,6 % a IoU 97,5 %.



Obr. B.11: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99,3 % a IoU 97 %.

C Výsledky 2D sítí po finálních úpravách

Tab. C.1: Tabulka výsledků testovaných 2D sítí po finálních úpravách pro metriku Jaccardův index (IoU) uvedenou v procentech. Ve sloupcích je (zleva) výsledek původní predikce, metoda aktivních kontur, kombinace 2D mediánového filtru s aktivními konturami a aktivní kontury s detektorem artefaktů.


číslo sítě	IoU [%]			
	predikce	kontury	filtr + kont.	kont. + det.
1	87,99	87,55	87,46	88,02
2	90,35	89,98	89,94	90,39
3	90,75	90,70	90,09	90,99
4	89,38	88,75	88,43	89,40
5	91,43	91,10	90,76	91,69
6	91,74	91,27	90,45	91,66
7	90,30	90,04	89,58	90,77
8	85,68	85,25	85,17	85,80
9	87,72	88,10	87,75	88,22
10	90,22	89,71	89,16	90,60
11	87,27	86,79	86,07	87,19
12	89,33	89,30	89,08	89,69
13	87,00	87,10	86,61	87,71
14	89,32	88,99	88,34	89,99
15	90,63	90,07	89,63	91,33
16	90,27	89,77	89,48	90,33
17	89,64	89,33	88,68	89,73
18	88,31	87,99	87,82	88,94
19	88,54	88,43	87,69	88,85
20	91,31	90,81	90,18	91,35
průměr	89,36	89,05	88,62	89,63
sm. odchyl.	1,59	1,53	1,48	1,57

D Výsledky 3D sítí

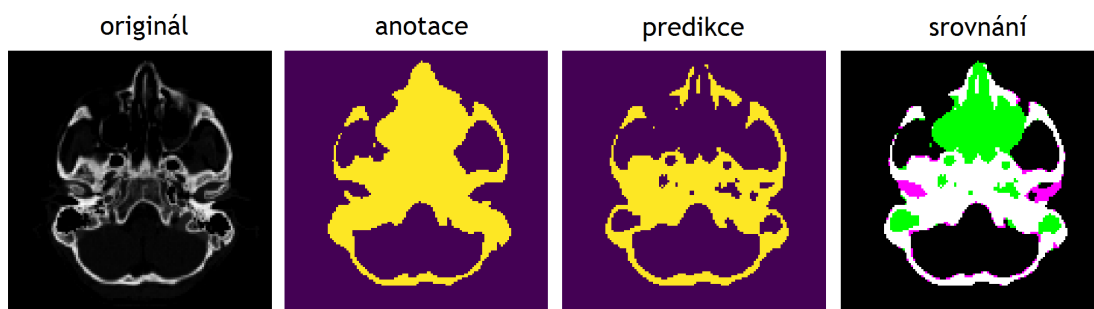
Tab. D.1: Tabulka výsledků 3D sítí pro metriku přesnost (ACC) a Jaccardův index (IoU) uvedených v procentech včetně jejich průměru a směrodatné odchylky.

číslo sítě	ACC [%]	IoU [%]
1	98,07	73,23
2	98,04	73,91
3	96,88	46,68
4	98,50	78,87
5	97,72	69,25
6	97,49	65,17
7	97,62	58,76
8	96,57	60,11
9	96,13	54,82
10	98,51	79,27
11	97,35	70,38
12	97,76	71,63
13	97,71	67,73
14	96,17	57,51
15	97,53	64,85
16	97,53	63,18
17	97,76	70,03
18	97,82	70,42
19	97,93	73,72
20	98,17	72,86
průměr	97,56	67,12
sm.odchyl.	0,65	8,08


E Ukázky výstupů testování 3D sítí




Obr. E.1: V části porovnání jsou pixely: TP bílou, TN černou, FP modrou a FN zelenou barvou. ACC tohoto řezu je 99,3 % a IoU 92,5 %.



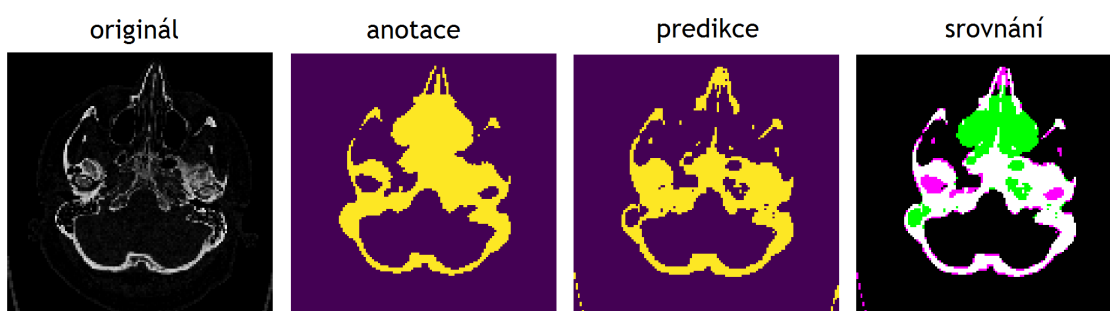
Obr. E.2: V části porovnání jsou pixely: TP bílou, TN černou, FP modrou a FN zelenou barvou. ACC tohoto řezu je 88,8 % a IoU 59,7 %.



Obr. E.3: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 98,5 % a IoU 84,5 %.



Obr. E.4: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 99 % a IoU 87,3 %.



Obr. E.5: V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. ACC tohoto řezu je 91,1 % a IoU 57,8 %.

F Srovnání 2D a 3D sítí


Tab. F.1: Tabulka srovnání výsledků 2D a 3D sítí, jejich průměrů a směrodatných odchylek, pro metriku ACC v procentech.

pacient	průměr [%]		sm. odchyl. [%]	
	2D	3D	2D	3D
1	98,91	97,68	0,07	0,37
2	99,50	98,05	0,06	0,35
3	98,40	97,45	0,26	0,24
4	99,10	98,20	0,07	0,34
5	99,88	99,65	0,06	0,19
6	99,05	98,18	0,10	0,35
7	99,22	97,64	0,11	0,36
8	98,80	97,62	0,29	0,29
9	99,78	99,44	0,04	0,24
10	98,18	96,15	0,27	0,31
průměr	99,08	98,01	0,13	0,30


Tab. F.2: Tabulka srovnání výsledků 2D a 3D sítí, jejich průměrů a směrodatných odchylek, pro metriku IoU v procentech.

pacient	průměr [%]		sm. odchyl. [%]	
	2D	3D	2D	3D
1	90,68	70,43	0,60	4,87
2	93,34	73,67	0,78	4,82
3	72,87	45,81	3,70	11,90
4	89,00	74,09	0,77	4,52
5	97,70	92,24	1,11	4,23
6	89,64	74,50	1,09	5,32
7	90,28	68,02	1,20	4,96
8	87,69	61,09	2,44	3,87
9	95,97	87,65	0,68	5,02
10	86,15	55,75	1,99	4,13
průměr	89,33	70,32	1,44	5,36


G Grafické srovnání 2D a 3D sítí



Obr. G.1: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP modrou a FN zelenou barvou. Srovnání predikce 2D sítí oproti anotaci: ACC 98,7 %, IoU 79,4 %. Srovnání predikce 3D sítí oproti anotaci: ACC 95,9 %, IoU 42,3 %.



Obr. G.2: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP modrou a FN zelenou barvou. Srovnání predikce 2D sítí oproti anotaci: ACC 99,4 %, IoU 95,5 %. Srovnání predikce 3D sítí oproti anotaci: ACC 94,4 %, IoU 61,3 %.




Obr. G.3: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,7 %, IoU 95,4 %. Srovnání predikce 3D sítě oproti anotaci: ACC 98,9 %, IoU 84,3 %.




Obr. G.4: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 98,1 %, IoU 88,3 %. Srovnání predikce 3D sítě oproti anotaci: ACC 93,8 %, IoU 63,1 %.



Obr. G.5: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,7 %, IoU 93,9 %. Srovnání predikce 3D sítě oproti anotaci: ACC 99,5 %, IoU 89,5 %.




Obr. G.6: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,9 %, IoU 98,7 %. Srovnání predikce 3D sítě oproti anotaci: ACC 99,1 %, IoU 88,4 %.




Obr. G.7: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99 %, IoU 93,7 %. Srovnání predikce 3D sítě oproti anotaci: ACC 93,1 %, IoU 56,6 %.



Obr. G.8: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 98,8 %, IoU 87,9 %. Srovnání predikce 3D sítě oproti anotaci: ACC 97,3 %, IoU 74 %.




Obr. G.9: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,4 %, IoU 90,7 %. Srovnání predikce 3D sítě oproti anotaci: ACC 96,2 %, IoU 52,3 %.




Obr. G.10: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,4 %, IoU 92,2 %. Srovnání predikce 3D sítě oproti anotaci: ACC 96,7 %, IoU 69,1 %.




Obr. G.11: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 98,8 %, IoU 91,5 %. Srovnání predikce 3D sítě oproti anotaci: ACC 92,5 %, IoU 55 %.



Obr. G.12: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,9 %, IoU 97,5 %. Srovnání predikce 3D sítě oproti anotaci: ACC 99,2 %, IoU 88,8 %.



Obr. G.13: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 99,8 %, IoU 97 %. Srovnání predikce 3D sítě oproti anotaci: ACC 98,9 %, IoU 86,8 %.



Obr. G.14: Grafické srovnání výstupu 2D a 3D sítě. V části porovnání jsou pixely: TP bílou, TN černou, FP růžovou a FN zelenou barvou. Srovnání predikce 2D sítě oproti anotaci: ACC 98,4 %, IoU 85,3 %. Srovnání predikce 3D sítě oproti anotaci: ACC 93,2 %, IoU 45,2 %.